

Utjecaj digitalne transformacije na poslovne i tržišne mogućnosti te prijedlozi stvaranja novih vrijednosti

Tomić, Dražen

Master's thesis / Specijalistički diplomski stručni

2019

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Algebra University College / Visoko učilište Algebra**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:225:435965>

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

Download date / Datum preuzimanja: **2024-11-06**



Repository / Repozitorij:

[Algebra University - Repository of Algebra University](#)



VISOKO UČILIŠTE ALGEBRA

DIPLOMSKI RAD

**Utjecaj digitalne transformacije na poslovne i
tržišne mogućnosti te prijedlozi stvaranja
novih vrijednosti**

Dražen Tomić

Zagreb, ožujak 2019

Predgovor

Pisanom izjavom posvećujem ovaj rad svima koji su zaslužni za jednu od mojih najluđih odluka u tim nekim godinama opet sjesti u studentske klupe. Jer neki su govori „pa što ti to treba“.

I pokazalo se to kao genijalna odluka, nakon dvadesetak i malo više godina novinarstva, fotografije i videa opet učiti o internetu i digitalnom marketingu iz neke nove perspektive, od profesora i ljudi s Algebre koje jako cijenim i s kojima sam izrastao u tom istom digitalnom svijetu.

Danas govoriti o digitalnom marketingu, izazovima digitalizacije i digitalne transformacije iz perspektive kad znaš kako je nastao tvoj prvi web negdje davne 1995. godine u VI editoru je iskustvo koje se ne može platiti. Znaš vrijeme kada nije bilo računala, kada su se pojavila prva, kad nije bilo iPhona. Puno godina i puno iskustva.

Stoga hvala mojim roditeljima, Ivani, Tei, Tineku, bratu, ali i mnogim prijateljima koji su me trpjeli u mojim poduzetničkim ludovanjima koja su rezultirala odlaskom na studij digitalnog marketinga na Algebri.

Hvala svim kolegama s prve i nezaboravne generacije digitalnog marketinga na Algebri – Helena & Helena, Dijana, Antonija, Toni, Srečko, Tin, Alen, Pavo, Tomislav, Mirjana. Posebno hvala Heleni na svojoj pomoći.

Hvala svim profesorima kojima nije bilo lako, nekima baš nimalo, ali bilo je to odlično iskustvo. I nadam se da ste uživali kao i ja.

Hvala Hrvoju, Mislavu i Tomislavu koji su stvorili Algebru, jer je to bilo zaista zanimljivo putovanje.

Hvala mentoru dr.sc. Leu Mršiću.

Sažetak

Hrvatski

Novonastala digitalna transformacija predstavlja značajnu promjenu u primjeni novih poslovnih modela koja je nastala kao rezultat umrežavanja ljudi (Social networks) i stvari (IoT). Velika količina podataka sve se više pretvara u vrijedne informacije putem kojih organizacije, ukoliko žele opstati na tržištu, moraju mijenjati svoje strateške odluke, temeljiti ih na strategiji optimizacije i inovacija. U ovom je radu, predstavljena analiza digitalne transformacije o napuštanju/ ostajanju korisnika u telekomunikacijskoj industriji. U nastavku slijedi prikaz digitalne transformacije i disruptivnih inovacija, prediktivni modeli: Logistička regresija, Stablo odlučivanja, Random Forest koji će dati uvid u sprječavanju odlaska klijenata k konkurenciji te je prikazanost obuhvatnost i preciznost predstavljenih modela.

Ključne riječi: digitalna transformacija, napuštanje/ostajanje klijenata, telekomunikacijske usluge, prediktivna analiza

English:

The new digital transformation represents a significant change in the exemplary new business models that have emerged as a result of social networking and stuff (IoT). A large amount of data is increasingly transformed into valuable information through which organizations if they want to survive in the market, must change their strategic decisions, base them on the optimization and innovation strategy. In this paper, an analysis of the digital transformation on the abandonment/retention of users in the telecommunications industry is presented. Below you will find a presentation of digital transformation and disruptive innovations, predictive models: Logistic Regression, Decision Tree, Random Forest, which will give insight into preventing clients from leaving the competition and showing the comprehensiveness and precision of the presented models.

Keywords: digital transformation, churn, telecommunication services, predictive analysis

Sadržaj

1.	Uvod.....	1
2.	Digitalna transformacija u poslovanju	4
2.1.	Disruptivne inovacije	6
3.	Telekomunikacijska industrija	10
3.1	Nadolazeći trendovi u industriji	12
3.2	Prilika za rast	13
3.3	Promjena poslovnih modela - AI i strojno učenje.....	16
3.3.1	Iskustvo prodaje i personaliziranog korisnika.....	19
3.3.2	AI trendovi	20
3.4	Rast prihoda.....	22
4.	Metode predikcije.....	24
4.1	Odlazak korisnika.....	26
5.	Metodologija istraživanja	28
5.1	Ciljevi istraživanja.....	28
5.2	Hipoteze istraživanja	28
5.3	Metoda istraživanja	28
5.3.1	Obilježja klijenata	29
5.3.2	Korelacija numeričkih varijabi.....	30
5.4	Logistička regresija	35
5.5	Stablo odlučivanja	36
5.5.1	Prednosti.....	38
5.5.2	Nedostaci	38
5.6	Random Forest modeliranje	39
5.6.1	Prednosti.....	39
5.6.2	Nedostaci.....	39

5.7	Obuhvatnost i preciznost modela	41
5.8	Kumulativna dobit.....	44
6.	Zaključak istraživanja	46
	Literatura	47
	Ilustracije.....	48

1. Uvod

Digitalna transformacija postala je sveprisutni pojam, posebice kada je u pitanju industrija 4.0, *Internet of Things (Iot)* koji predstavlja važan aspekt digitalne transformacije, tehnološki razvoj, poslovni razvoj i strategije s kojom organizacije dolaze i/ili ostaju na tržištu. Kao što samo ime nagovještava, ona podrazumijeva mijenjanje srži i osnove organizacija, njihovih dosadašnjih poslovnih modela korištenjem raznih digitalnih tehnologija. Kako bi organizaciju smatrali digitalnom neophodno je i ključno da jedan dio svog poslovnog modela temelji na digitalnoj tehnologiji. Prema istraživanjima analitičke tvrtke Futurum [1] za 2017. godinu 2/3 tvrtke potvrdile su implementaciju IoT-a u svojim poslovnim modelima, točnije njih 54.2% nešto je poduzelo u svo poslovnom modelu primjenjući tehnologiju IoT-a, dok njih svega 13.8 % implementiralo IoT, dok njih svega 32% nije uopće. Ovo istraživanje ukazuje kako će IoT-a u narednim godinama rasti, sa više uređaja koji se će se pojavljivati iz dana u dan. Predviđanja za 2018. također ukazuju kako će industrija IoT-a postati okosnica buduće vrijednosti klijenta, infrastruktura IoT-a prebaciti će se na rub i specijalizirane IoT platforme, razvojni programeri imat će značajan utjecaj na platforme i inicijative, a sigurnost će ostati ključni interes svake organizacije.[2] Dok tradicionalne industrije, s proizvodnjom na čelu ulažu napore u digitalizaciji svojih tvornica, tehnološke tvrtke poput IBM-a, Googlea i Microsofta razvijaju učenje, kognitivne IT sustave koji kao varijanta umjetne inteligencije namjeravaju napraviti strojeve, postrojenja i druge digitalne sustave pametnima. S obzirom da je digitalna transformacija drugačija za svaku organizaciju teško se može pojmovno definirati njezino značenje. No, generalno, ona predstavlja integraciju digitalne tehnologije u sva područja poslovanja, što rezultira temeljnim promjenama u načinu poslovanja i načinu na koji korisnicima pružaju dodanu vrijednost. Upravo ta transformacija predstavlja odmak od dugogodišnjih poslovnih procesa na kojima su tvrtke osnovane u korist relativno novih praksi koje se još definiraju. Prema IDC istraživanju „FutureScape: Worldwide Digital Transformation 2018 Predictions” ukazuju da će do 2019. godine potrošnja digitalne transformacije doseći 1,7 bilijuna dolara diljem svijeta, što predstavlja porast za 42% od 2017. godine.[3] Nadalje, isto istraživanje ukazuje na zabrinutost za organizacije ukoliko ne uvedu promjene u svojim poslovnim modelima. Razlog tome su sukobljavanje imperativima digitalne transformacije, neučinkovite tehnološke inovacije, tranzicije infrastrukture *cloud*, nedovoljno novčanih sredstva za ulaganje u osnovne sustave. Nasuprot tome, u posljednjem

Gartnerovom istraživanju, 56% tvrtki tvrdi kako su digitalna poboljšanja već dovela do veće dobiti. [4]

Istraživanja nad provedenim promjenama u organizacijama sukladno digitalnoj transformaciji ukazuju na rad i razvoj tvrtki, potvrđujući široko prihvaćene modele transformacije u svojim poslovnim modelima donosi niz promjena u svim gospodarskim granama s jedne strane te ekonomiji s druge. Telekom industrija suočava se s teškim vremenima s obzirom da digitalizacija preoblikuje industrije. Prema istraživanju različitih industrijskih lidera u industriji za 2015. godinu, u istraživanju više od 2000 C-razine izvršnih direktora iz 15 industrija, njih 64% telekom direktora i 72% direktora medija očekuju umjerenu ili masivni digitalni poremećaj u narednih 12 mjeseci. Konkurentske granice se mijenjaju, korištenje poruka i dalje se smanjuje, dijelom pod regulatornim pritiscima, ali i zbog toga što društveni mediji otvaraju nove komunikacijske kanale. Odljev korisnika predstavlja antitezu rastu, ukoliko se izgubi jedan kupac, kako bi tvrtka rasla po jednom korisniku mora najprije zamijeniti tog korisnika kojeg je izgubila te zatim dodati novog korisnika. Ono što je zapravo gore od odljeva korisnika je ne znanje zašto je otišao. Istraživanje Statista iz 2017. godine ukazuje stopu odljeva kupaca u SAD-u po djelatnostima. Te je godine u telekom industriji odljev iznosio 20%. [5] Kako bi se dobio uvid zašto se uopće događa odljev korisnika, prikupljeni su relevantni podaci o klijentima na temelju kojih se može predvidjeti ponašanje u svrhu zadržavanja klijenata. Podaci su prikupljeni s platforme Kaggle, kvantificirani i analizirani u svrhu ukazivanja kako se može spriječiti odljev korisnika ukoliko se koriste prediktivni modeli. Izračun vrijednosti trajanja klijenata mogu imati koristi od uvida u odljevu korisnika s obzirom da se postotak odljeva korisnika u svim granama industrije povećava te upravo provedeno istraživanje može se iskoristiti kao doprinos za izgradnju sustava koji će na vrijeme detektirati potencijalni odljev korisnika u telekom industriji.

Započinjemo s predstavljanjem pozadine digitalne transformacije i opisom poslovnih procesa prije digitalne transformacije, usklađenost poslovnih procesa kroz prilike i izazove, alatima digitalne transformacije, trendovima u telekomunikacijskoj industriji, AI trendovi. Nakon toga, predstavljeni su rizici u promjeni strategija organizacija, model vrijednosti trajanja klijenata te kretanja odljeva u industrijama. Kako bi smo razumjeli odljev korisnika u telekom industriji prikazana je model koji uvelike može pripomoći kod zadržavanja korisnika te je iz tog razloga predstavljen rezultat odljeva u telekom industriji. Opisane su tehnike korištene prilikom klasifikacije seta podataka nad kojima su zatim provedeni

prediktivni modeli logističke regresije, stablo odlučivanja te Random Forest. Navedeni modeli ukazat će postojati li odnos i povezanost između varijabli te koliko su korišteni modeli pouzdani, precizni i točni.

2. Digitalna transformacija u poslovanju

Organizacije mogu intenzivno koristiti digitalnu tehnologiju, no to nužno ne znači da su digitalno transformirali svoje poslovanje. Kako bi se valjano predstavila digitalna transformacija neophodno je da se definiraju pojmovi poput digitalni poslovni modeli, digitalna transformacija.

Digitalno poslovni modeli prema Spremić: *„predstavljaju sve poslovne aktivnosti koje se odvijaju elektroničkim putem i uz pomoć digitalnih tehnologija, a kojima se intenzivnim elektroničkim povezivanjem s okruženjem stvara nova vrijednost i koriste prednosti poslovanja u digitalnoj ekonomiji.“* Odnosi se na *„prilagodbu načina i modela poslovanja u uvjetima digitalne ekonomije s ciljem pronalaženja održivih izvora prihoda i dodane vrijednosti novog modela poslovanja koji intenzivno koristi digitalnu tehnologiju.“* Upravo na temelju navedenog potrebno je iz temelja promijeniti način provedbe poslovnih procesa.

Digitalna transformacija poslovanja prema Spremić: *„odnosi se na stalnu promjenu digitalnih tehnologija usmjerenu na osmišljavanju inovativnih poslovnih strategija i disruptivnih poslovnih modela, primjeni progresivnih koncepcija poslovanja, novih načina vođenja i upravljanja kako bi se kupcima ponudili bolji proizvodi, usluge i osobito iskustva njihova korištenja.“* Pod time se podrazumijeva korištenje digitalnih tehnologija kako bi kupcima stvorila nova vrijednost dok za poduzeće ono predstavlja bolje poslovne prihode i općenito bolji rezultat poslovanja. Upravo ta promjena potiče na digitalnu reorganizaciju poslovanja koju trebaju pratiti suvremene digitalne tehnologije. Digitalne tehnologije, odnosno suvremeni informacijski sustavi prikupljaju, pohranjuju, obrađuju, analiziraju i distribuiraju podatke, informacije i znanje te pronalaze strategiju s kojom nastupaju na tržištu. Naime, dodana vrijednost ne pronalazi svoju srž u pohranjivanju i distribuciji resursa već u sveobuhvatnom procesu korištenjem različitih digitalnih tehnologija, na temelju analize, korelacije i novih informacija, temeljem velike količine podataka stvaraju i dokazuju kroz svoje poslovanje znanje.

Iako tehnologija igra važnu ulogu u pokretanju strategije digitalne transformacije, implementacija i prilagođavanje masovnim promjenama koje dolaze s digitalnom transformacijom utječe na svaku organizaciju. Upravo iz tog razloga, digitalna transformacija najveći problem nailazi u ljudima. Kada govorimo o promjeni tehnologije, bilo da se radi o Internetu, velikoj količini podataka ili strojno učenje, ova promjena ovisi o

ljudima i organizacijskoj kulturi prije svega. Preobrazba organizacijske kulture ključan je faktor u promjeni poslovnog modela, odnosno digitalnoj transformaciji poduzeća. Iako ona uključuje različite tehnologije, fokus većina tvrtki je na *cloud computing*, Internet stvari (IoT), veliki podaci i umjetna inteligencija. Koliko je digitalna transformacija važna govori podatak IDC-a kako će do kraja 2018. godine izdaci na svjetskoj potrošnji na tehnologijama digitalne transformacije (DX) što uključuje hardver, softver i usluge iznositi gotovo 1,3 bilijuna dolara, što je u odnosu na 2017.godine porast od 16,8 % u odnosu na potrošenih 1,1 trilijuna dolara.

Ažuriranje izdavanja *Worldwide Semiannual Digital Transformation Spending Guide* iz International Data Corporation (IDC) prognozira potrošnju na digitalnu transformaciju kako bi se održao snažan tempo rasta tijekom predviđenog razdoblja 2016-2021. uz složenu godišnju stopu rasta (CAGR) od 17,9%

Do 2021.godine DX potrošnja gotovo će se udvostručiti na više od 2,1 trilijuna dolara. Većina izdataka koje tvrtka ima u procesu digitalne transformacije u 2018.godine biti će usmjerena prema tehnologijama koje podržavaju nove ili proširene operativne modele u svrhu postizanja učinkovitosti i responzivnosti iskorištavanjem digitalno povezanih proizvoda, usluga, imovine, ljudi i trgovinskih partnera s ciljem udovoljavanja jedinstvene i individualizirane potražnje. Informacije (podaci) također će biti važan aspekt digitalne transformacije, njezinog investicijskog ulaganja (240 milijarde dolara u 2018.godini) jer organizacije nastoje dobiti i iskoristiti informacije za postizanje konkurentske prednosti kroz bolje odlučivanje, optimizaciju operacija te novih proizvoda i usluga. [6]

Poslovanje u digitalnoj ekonomiji podrazumijeva digitalnu transformaciju, stoga je važno naglasiti što ona zapravo nije:

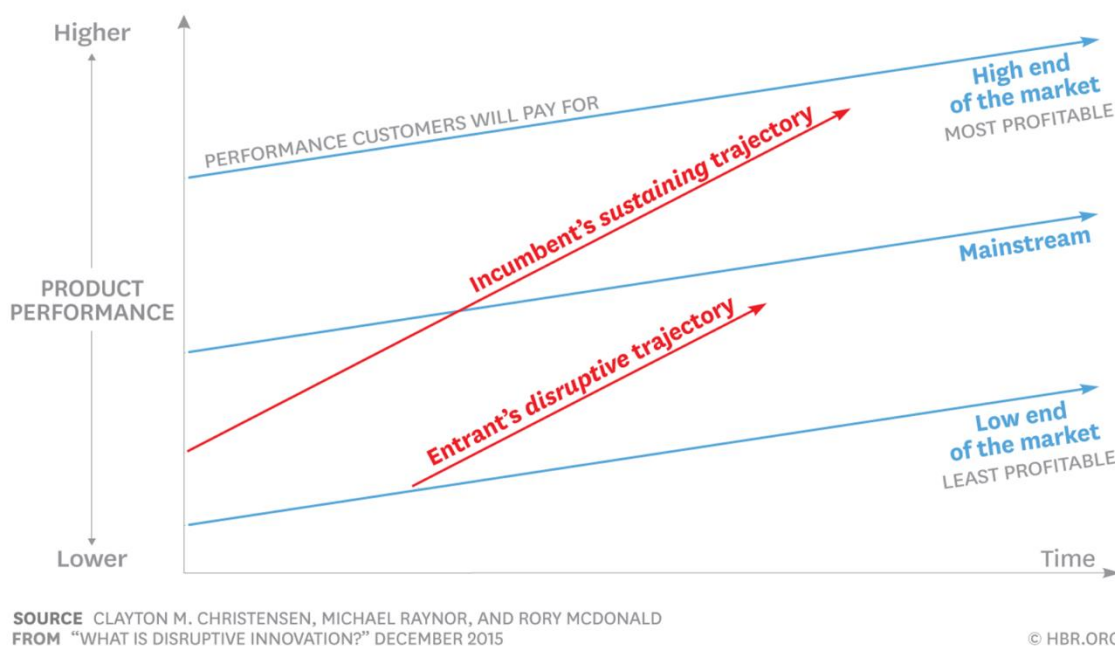
- a) samo za tehnološke organizacije
- b) ne podrazumijeva samo digitalni marketing
- c) korištenje novih tehnologija

2.1. Disruptivne inovacije

Informacijsko doba koje je svoj pun zamah doživjelo nakon pojave osobnih računala i uspostavom globalne mreže. ICT tehnologija paralelno se razvijala s digitalnom revolucijom te su analogni uređaji koji su služili za komunikaciju i prijenos informacija prolazili kroz proces digitalizacije. Upravo iz te činjenice s novom tehnološkom revolucijom došlo je do potrebe za promjenom na tržištu rada te utjecala na brisanje granica slobodnim protokom roba, usluga, kapitala i ljudi. Iako je digitalna transformacija već duboko zahvatila svjetsku ekonomiju, upravljanje podacima, iako je postojalo i prije digitalizacije, rad s podacima počeo se prakticirati s digitalizacijom. Podaci su postojali i prije digitalizacije, no digitalni alati omogućili su praktičnije poslovne strategije i nove značajne poslovne modele. Također, digitalizacija je utjecala i na promjenu u načinu poslovanja i stvaranja novih poslovnih modela u kojima je provedba promijenjena iz temelja. Proces radikalnih promjena od uobičajenih poslovnih modela, odnosno proces u kojem manja tvrtka s manje resursa uspijeva uspješno izaziva uhodani posao. Kako se uhodane prakse fokusiraju na unaprjeđenje svojih proizvoda i usluga za svoje najzahtjevnije i obično najprofitabilnije kupce, premašuju potrebe nekih segmenata i zanemaruju potrebe drugih. Sudionici koji dokazuju disrupciju započinju s uspješnim ciljanjem onih segmenata koji su zanemareni, dobivajući uporište davanjem više prikladnih funkcija često po nižoj cijeni. Nositelji u stremljenju ka većoj profitabilnosti u zahtjevnijim segmentima teže blažim reakcijama. Tada se novopridošli kreću uzlazno u odnosu na tržište isporučujući performanse koje kupci nositelja zahtijevaju, istovremeno čuvajući prednosti koje su im omogućile rani uspjeh. Kada mainstream kupci počinju prihvaćati ponude novopridošlica u većim količinama javlja se poremećaj u sistemu.

Disruptivne tehnologije su one koje mijenjaju ustaljene poslovne procese, industrije, pristupajući s novim modelom poslovanja utemeljenim na tehnologiji. Industriju 4.0 prate inovacije koje su prioritet svima tvrtkama u vidu opstojanja na tržištu. Disruptivni proizvodi ili usluge usmjereni su na tržište koje prije nije bilo podmireno (nova disrupcija na tržištu) ili predstavlja jeftiniju, ekonomičniju ili jednostavniju alternativu postojećim proizvodima

(jeftinija disrupcija). Google i Apple tvrtke su koje su prve digitalizirale svoje poslovanje. Apple je digitalizirao svoje poslovanje proizvodnjom i prodajom računala do vlasnika i operatera elektroničkih tržišta. U glazbenoj industriji Apple je svojim poslovnim modelom ukazao kako je predvodnik digitalne disrupcije stvaranjem iTunes-a te time omogućio na AppStore-u svima da stvaraju mobilne aplikacije i pritom dijele zaradu s vlasnikom, operaterom tržišta (Apple). U nastavku predstavljen je inovacijski disruptivni model koji je obilježio suvremeno tehnološko poslovanje.



Slika 1. Disruptivni model suvremenog tehnološkog poslovanja

Prema disruptivnom modelu, crvena linija predstavlja putanju izvedbe proizvoda ili usluga kroz vrijeme u odnosu na plavu liniju koja predstavlja putanju zahtjeva kupaca, odnosno koliko su spremni platiti za njihovo izvođenje. Kako *incumbent* tvrtke upoznaju potencijalne klijente s visokom kvalitetom proizvoda ili usluga (gornja crvena linija) s ciljem zadovoljavanja *high end* tržište u kojem je profitabilnost najviša premašuju potrebe *low end* klijenata kao i mnogih *mainstream* kupaca. Upravo u ovom djelu ostavlja se prazan hod za pronalazak uporišta u manje profitabilne segmente koje *incumbents* odbijaju. Ulazak u disruptivnu putanju (crvena donja linija) poboljšava izvođenje njihovih ponuda i kretanja na tržištu (u kojima je profitabilnost visoka) kao i izazova u dominaciji *incumbents*.

Digitalizacija je predstavila modele digitalne disrupcije u mnogim industrijama prema kojima su nastale mnogi današnji lideri globalnih digitalnih platforma koje je Spremić svrstao u [7]:

- Digitalne platforme za rezervaciju (Airbnb, Booking.com, Nextdoor)
- Digitalne platforme za prijevoz (Uber, Blablacar, DriveNow, Bolt, Lyft)
- Digitalne industrijske platforme (General Electric)
- Digitalne platforme za komunikaciju (Facebook, Twitter, Snapchat, Instagram, LinkedIn)
- Digitalne platforme za trgovinu (Amazon, eBay, Alibaba)
- Digitalne platforme za plaćanje (mPesa, PayPal, Apple Pay, Google Wallet, Revolut)
- Digitalne platforme za marketing (Google, Facebook, Instagram)
- Digitalne platforme za obrazovanje (Coursera, edX, Udacity)
- Digitalne platforme za proizvodnju (Adidas 3D Future Craft, Adidas Speedfactory)

Prema tome, disrupcija se očekuje da će pogoditi sve sektore prije ili poslije. U budućnosti možemo očekivati stvaranje digitalnih platformi za poljoprivredu, proizvodnju hrane, zdravstvene skrbi, javnu upravu itd. Apple je u siječnju ove godine predstavio značajni *update* u svojoj *Health* aplikaciji i time omogućio svojim korisnicima da vide svoje zdravstvene podatke na svom mobilnom uređaju. Omogućio je povezivanje s različitim institucijama organiziranih u jednom pogledu organiziranih u elemente alergija, stanje, imunizacija, laboratorijski rezultati, lijekovi, procedure i vitalni elementi. Također, korisnici primaju i obavijesti kada se njihovi podaci ažuriraju. Podaci o zdravstvenoj evidenciji kriptirani su i zaštićeni korisnikovom zaporkom[8]. Nadalje, uz Apple također i Microsoft, Google, Amazon, Intel i Samsung imaju platforme kojima je naglasak na pohranjivanju zdravstvenih podataka u sigurnosnim oblacima. Nasuprot njima, ostale zdravstvene platforme poput Dutch Quli i VieDome, belgijski Cubigo i finski Active Life Village ciljaju stariju i kroničnu populaciju prema kojima je cilj samostalne brige o zdravlju preko aplikacija. Sukladno tome, možemo primijetiti kako će se sektor zdravlja razvijati u smjeru *consumer-friendly* pristupa, stvarajući Zdravstvene Evidencije baziranih na engl. *FHIR* (*Fast Healthcare Interoperability Resources*), standard za prijenos elektroničkih medijskih evidencija¹. Nadalje, tvrtka Netflix revoluzionizirala je način na koji ljudi gledaju TV. Netxlix-

¹ <https://www.apple.com/newsroom/2018/01/apple-announces-effortless-solution-bringing-health-records-to-iphone/>

ovo iskustvo postignuto je s brojnim algoritmima rangiranja, optimiziran za različite svrhe. Uzimo za primjer *Top Picks* red na početnoj stranici koji radi preporuke temeljnom na personaliziranom rangiranju videozapisa videa, te *Trending Now* red koji uključuje i nedavne popularne trendove. Ovi algoritmi sa mnogim drugima koriste se za izradu personaliziranih početnih stranica za više od 100 milijuna članova. Element svoje uspješne strategije temelje na eksperimentalnom A/B testiranju. Netflix ne predstavlja samo servis za *streamanje* sadržaja, već je tvrtke orijentirana na podatke koja koristi sustave koji joj omogućuju da prati korisnike te optimizira marketing te dostavlja bolji produkt. Bez analitike tvrtke su u crnom prostoru sa kupcima, ona daje poslovanju kvantitativne podatke koji su potrebni za bolji, informiranije odluke i poboljšanja usluge. U srpnju, Netflix je mjerio 130 milijuna pratitelja globalno, što govori koliko veliku količinu podataka prikuplja².

Iskustvo Netflixa pokreće obitelj algoritama rangiranja, svaki optimiziran za drugu svrhu. Na primjer, redak na vrhu popisa na početnoj stranici donosi preporuke temeljene na prilagođenom rangiranju videozapisa, a redak "Trend sada" uključuje i nedavne trendove popularnosti. Ovi algoritmi, zajedno s mnogim drugima, koriste se zajedno za izradu personaliziranih početnih stranica za više od 100 milijuna članova. Koliko zapravo Netflix zna o korisniku govori sljedeći primjer. Uzmimo za primjer Netflixovu seriju *Stranger Things*, Netflix je u mogućnosti da vidi stopu završetka korisnikovog pregleda serije, te postavlja sljedeće pitanje, Koliko korisnika koji su počeli gledati seriju *Stranger Things* (od prve sezone) završili s gledanjem do sezone 3. Kada dobiju odgovor (recimo da je to 70% korisnika) postavljaju pitanje *Gdje je bila zajednička točka odsjeka za korisnike, što je sa 30% korisnika, što su oni uradili?* Koliko je veliki vremenski *gap* između korisnika koji su pogledali epizodu i onih koji su pogledali sljedeću. [9]

U trenutku kada su prikupili podatke i pogledali trend korisnika kako bi shvatili involviranost na višoj razini. Ukoliko je Netflix procjenio 70% korisnika koji su pogledali sve sezone od onih otkazanih, ovo može izazvati zanimanje za ponovno gledanje *Stranger Things*. No podaci pomnije ukazuju kako Netflix prati i prikuplja podatke:

- Kada pauziramo, prevrtimo ili ubrzamo

² https://s22.q4cdn.com/959853165/files/doc_financials/quarterly_reports/2018/q2/FINAL-Q2-18-Shareholder-Letter.pdf

-
- Koje dane gledate koji sadržaj (s obzirom da se temeljem analize pokazalo kako ljudi gledaju TV serije tijekom tjedna dok preko vikenda odabiru filmove)
 - Datum kada ste gledali
 - U koje ste vrijeme gledali sadržaj
 - Gdje gledate (zip code)
 - Koje uređaje koristite za gledanje
 - Kada ste pauzirali ili napustili sadržaj (i ako se ikada vratite)
 - Ostavljene ocjene (oko 4 milijuna dnevno)
 - Pretrage (oko 3 milijuna dnevno)
 - Pregledavanje i vrtnja ponašanja
 - Također uvid u podatke u filmovima, uzimaju različite „screenshots“ u stvarnom vremenu kako bi otkrili karakteristike

Svojom analitikom, Netflix može znati koliko sadržaja korisnik mora pogledati kako bi manje odustajao. [10] Na primjer, možda znaju „Ako mogu dovesti svakog korisnika da pregleda najmanje 15 sati sadržaja svakog mjeseca, 75% manje je vjerojatno da će otkazati. Ukoliko padnu ispod 5 sati, postoji 95% šanse da će otkazati.“³

S druge strane, primjer disruptivne inovacije predstavlja Airbnb, tvrtka koja omogućuje korisnicima pregled smještaja, odgovarajući hotel, hostel ili privatni smještaj. [11]

Airbnb koristi poslovni model koji klijentima omogućava novi način iznajmljivanja doma i unajmljivanja smještaja, što mijenja način na koji ljudi koriste svoje resurse i pronalaze smještaj.⁴

3. Telekomunikacijska industrija

U posljednjih desetak godina, telekomunikacijska industrija, nakon liberalizacije tržišta, privatizacije monopolista, proširila se i napredovala. Nadalje, jedna od ključnih izazova telekomunikacijske industrije jesu očekivanja i standardi informacijske sigurnosti. Zaštita IT

³ <https://neilpatel.com/blog/how-netflix-uses-analytics/>

⁴ <https://futuretravel.today/most-disruptive-business-model-airbnb-d65eed9c10df>

infrastrukture i aplikacija od neovlaštenih aktivnosti te osiguranje zaštite osjetljivih poslovnih informacija izazov su s kojima su suočavaju telekomunikacije u vidu održavanja konkurentne prednosti na tržištu, od procesa prodaje do razvoja novih usluga i proizvoda. S obzirom na zaštitu osobnih podataka, kao posljednje regulative Europske Unije, u bazama podataka i drugim dijelovima telekomunikacijske infrastrukture pohranjene su značajne količine podataka koji su osjetljive vrste stoga je neophodno da telekomi izgrade zaštitne sustave koja će biti u skladu s pravima korisnika. Kao i svaka industrija, telekom industrija također prolazi kroz proces digitalne transformacije u vidu prilagođavanja novim tehnološkim i cloud trendovima. Iako je na početku fokus bio na komunikacijskoj tehnologiji koja je označavala prvi val informacijske ere, druga faza, Internet započela je 2000. godine industrija se uskladila oko horizontalnih rješenja tijekom ove faze te je započela faza e-trgovine i portala. Nakon 2006. godine, cloud, kao začetnik treće faze transformacije telekomunikacijske industrije započeo je svoj razvoj. Nove tehnologije poput IoT-a, AR-a, virtualne stvarnosti (VR), mikro usluga zahtijevaju usklađivanje poslovnih strategija od strane operatera u vidu cloud-a, operacija, arhitekture te mreža.

Kako bi se stekla konkurentna prednost, neophodno je da se telekomi usredotoče na pružanje prilagođenih rješenja svojim klijentima te razvijanje dugoročnih odnosa s njima. U nastavku su prema Deloittovim predikcijama predstavljeni izazovi telekom industrija u 2018. godini.

1. Telekomi moraju decentralizirati kupovnu i odlučujuću moć kako interno tako i eksterno, s obzirom na agilnost rekonfiguracije cloud-a
2. Uz dostupnost novih tehnologija, raznolikosti i kvalitete usluga od telekomunikacijskih tvrtki i davatelja usluga (ISP) povećava se, dok se profitne marže smanjuju, a linije između telekomunikacijskih tvrtki i tehnoloških dobavljača zamagljuju.
3. S novim pretplatnicima, raznovrsnošću proizvoda, grupiranim i prilagođenim rješenjima, operativne usluge podrške poput konfiguracije usluga, ispunjenje narudžbe, briga o korisnicima i naplata postaje veoma složen proces. Dakle, troškovi rukovanja navedenih operacija zahtijevaju resurse i različite alate prema kojima se povećava financijski opći troškovi.
4. Davatelji telekomunikacijskih usluga trebaju nadogradnju IT-a i infrastrukture povezivanja te kao neophodni zadatak jest usredotočenje na pružanje podataka i glasovnih servisa visoke kvalitete, pouzdanosti i pristupačnosti. Nadalje, sigurnost

mreža koja je postala glavni prioritet za telekomunikacije, potrebne su brojne operativne i tehničke inovacije kako bi se zadovoljila očekivanja korisnika o potpunoj sigurnosti sustava od mreže do razine uređaja.

5. Ključni izazov za telekomunikacije i ISP-e jest utjecaj IoT-a koji vodi do ekstremnog rasta u povezanim uređajima. Upravo taj rast generira milijarde i trilijarde novih izvora podataka, te se očekuje kako će taj rast potaknuti rješavanje podataka s mrežama na zettabytes godišnje.

3.1 Nadolazeći trendovi u industriji

Nadalje, nadolazeći trendovi za 2018. također ukazuju sljedeće:

1. 5G mreža – donijet će velike promjene u brzini mobilnog interneta. Na svjetskom nivou, 5G mreža očekuje se 2020. godine, a domaći i strani telekomi ulažu napore u izgradnji infrastrukture s obzirom da ona kao takva zahtijeva prilagodbu odašiljača i ostalih tehničkih komponenti.
2. Sigurne i pouzdane usluge – telekomunikacijsko okruženje nudi bogat spektar usluga kojima je potrebna pouzdana i sigurna provjera autentičnosti. Biometrijski čitači otiska prsta na pametnim uređajima je u porastu, te se očekuje kako će do kraja 2017. godine oni dosegnuti 1 milijardu. Ovu vrstu tehnologije koriste mnogobrojne industrije, od institucija, vlade, škola, sve u vidu provjere identiteta. Nadalje, biometrijske mehanizme poput prepoznavanja lica ili mrežnice također su u trendu te se očekuje kako će u sljedećih nekoliko godina upotreba ove vrste tehnologije znatno porasti. Uz to, sve veći broj telekomunikacijskih tvrtki usvaja biometrijske SIM kartice s ciljem sprječavanja i suzbijanja zločina vezanih uz mobilne telefone i terorističke napade.
3. Artificial Intelligence (AI) – omogućuje pametnim uređajima obavljanje sofisticiranih funkcija, poput one povećane stvarnosti (primjer Pokemon Go), unutarnje navigacije, prepoznavanje govora, pa sve do učenja svakodnevnih zadataka i preferencija pojedinaca koje omogućuje asistiranje od digitalnih pomoćnika poput Siri ili Alexa. Svoju primjenu AI ukazuje i kroz Chatbotove korisničke službe, djeluje poput prodajnog asistenta, kao primjer Century Link's, glasovnih usluga za korisnike putem kojih mogu istražiti ili kupiti sadržaj govorom, klasifikacijom prometa, optimizacijom mreže te predviđenim mrežnim održavanjem, poput AT&T-ovog programa za samoiscjeljivanje i samostalnim učenjem koje pokreću pomoću umjetne inteligencije neke su od primjera AI aplikacija koje koriste vodeći konglomerati telekomunikacijske industrije.

-
4. Internet of things (IoT) – s obzirom na veliku količinu podataka koje povezani uređaji generiraju, mogućnosti primjena IoT aplikacija su raznolike i široke te se prožimaju gotovo na sva područja ljudskog djelovanja. Kako bi se iskoristio potencijal IoT-a on mora biti korisnički orijentiran (user friendly), skalabilan, mobilan te siguran. Prema predviđanju Gartnera, do 2020. godine biti će priključeno gotovo 20 milijardi uređaja na IoT, te će se proizvodi i usluge dobavljača imati poslovanje s 300 milijardi dolara prihoda. Također, prema istraživanju tvrtke Tata Communications, sektor telekomunikacija četvrti je po pitanja trošenja na IoT tehnologiju. Telekomunikacijske tvrtke potrošile su otprilike 110.7 milijuna dolara na IoT u 2015. godini, dok će on rasti na 169.5 milijuna dolara do 2018. godine. Nadalje, korisnost IoT ogleda se u poboljšanju operativnih učinkovitosti daljnjim nadzorom i upravljanjem opreme, IT infrastrukture, postizanjem većih sigurnosti pomoću sustava za otkrivanje napada putem e-pošte i zaštite udaljenih lokacija od strane telekom industrije.
 5. Spajanje i akvizicija – s konkurencijom, novim tehnološkim inovacijama koje utječu na postojeću bazu korisnika nadolazeće godine predstavljaju izazov za telekomunikacijski sektor. Upravo iz tog razloga, brojne tvrtke traže partnerstva s medijskim i sadržajnim tvrtkama, poput AT&T koji je predložio spajanje s tvrtkom Times Time Warner Inc. u vidu razvijanja kvalitetnije strategije, smanjenje troškova video sadržaja s onim zabavnim koje Time Warner nudi.

3.2 Prilika za rast

Prinos prihoda nad podatkovnim uslugama (prihod po potrošenom bitu) i dalje se smanjuje s obzirom da potrošači koriste sve više i više podataka s statičnim ili smanjenim mjesečnim računima. Neophodno kao takvo jest identificirati brze investicijske prilike u portfelju telekomunikacijskih usluga, uključujući 5G mrežu, IoT i međusektorska partnerstva, poput mHealth i mPayments kao i niz drugih mogućnosti rasta. Telekomunikacijski ekosustav očekuje kako će IoT postati ključni motor budućeg rasta. Jedna od najuspješnijih IoT aplikacija jesu povezani automobili. Najveći američki prijevoznici u proteklih su nekoliko godina uložili značajna sredstva u povezane automobile, a njihov rast već vidimo u mobilnoj pretplati za povezana vozila. Povezani automobili, pored ostalih kategorija IoT-a i dalje će predstavljati važno područje rasta za prijevoznike u 2018. godini. Potencijal IoT-a proteže se daleko izvan samo povezanih vozila. Prilike uključuju povezanost potrošača i široki

spektar povezanih stvari s aplikacijama, kao što su povezanost kućnog nadzora i kontrole, zabave...Današnja tehnologija sposobna je proizvesti malene uređaje koje odlikuje praktičnost i veličina te svoju primjenu pronalaze u medicini, logistici, transportu...Gledajući van IoT-a, mnogi telekom operateri ulažu napore u vidu ulaska u medijske prostore kroz M&A ponude, partnerstva i slično. Mobilni sadržaji i videozapisi neki su od najznačajnijih potreba za 5G mrežom, stoga širenje u sadržajni aspekt predstavlja okosnicu rasta. Secondhand pametni uređaji također predstavljaju područje potencijalnog rasta u telekomunikacijskoj industriji. S pametnim uređajima koji se nastavljaju povećavati, sve više raste broj korisnika koji odbacuju svoje stare uređaje i kupuju nove u želji da zadovolje svoje preferencije. Prema Deloitteovom Globalnom istraživanju, broj potrošača koji su bacili svoje stare mobitele smanjio se za više od pola u samo jednoj godini, 2016. godine on je iznosio 12%, do 5% u 2017.godini. Upravo na temelju statistike, postoje mnogobrojne prilike za kapitaliziranjem rastuće vrijednosti upotrijebljenih pametnih telefona, kao i povećan volumen ulaska u ovo područje. Nadalje, iako su VR i AR još u nastajanju, prema Deloitteovom GMCS-u, oko 10% potrošača posjeduje VR slušalice, predstavljajući relativno brzu krivulju prilagodbe za ovakav novi proizvod. Kao što je gore spomenuto, 5G mreža zahtijevat će velika ulaganja u narednih nekoliko godina, uz ostala područja kao što su IoT i međusektorska partnerstva. Ulaganja u 5G mrežu (zajedno sa SDN/NFV i ostalim mrežnim nadogradnjama) pomoći će u smanjenju troškova isporuke usluga i poboljšati vrijeme ulaska na tržište. Osim toga, telekomi imaju veliku potražnju za investicijama vezanim uz *core fiber* mrežu. Dok se većina pozornosti 5G odnosi na bežičnu pokrivenost i potencijalne slučajeve korištenja koje će kao takva 5G mreža donijeti, uspjeh sljedeće generacije mobilne mreže oslanja se na značajno ulaganje u *core fiber* mrežu kako bi se podržao očekivani rast podatkovnih usluga. Prema Deloitt izvješću 2017. godine pod nazivom *The need for deep fiber*, očekuje se četverostruko povećanje mobilnog podatkovnog prometa u SAD-u razdoblju između 2016.-2021. godine. Ova analiza sugerira kako bi investicija od 130 milijardi dolara na 150 milijardi dolara trebala biti potrebna u sljedećih pet do sedam godina samo u SAD-u kako bi se na odgovarajući način podržala širokopojasno tržišno natjecanje, ruralna pokrivenost i bežična pokrivenost.

Osim toga, telekomi imaju uvijek prisutnu obvezu nastaviti osiguravati ažuriranja **legacy** IT sustava, posebice kada se proširuju na nova područja. Ovi legacy IT sustavi ključni su ali ujedno i skupi za telekomunikacijske davatelje te su fokus dalekosežnih napora za digitalnu transformaciju, namijenjeni poboljšanju usluga korisnicima, pojednostavljenje procesa,

konsolidacije ERP/ financijskih sustava... Novije, više transformativne tehnologije u vidokrugu za telekome uključuju robotiku, automatizaciju te blockchain. Također, značajne promjene očekuju se u korištenju mobilnih usluga potrošača u 2018. godini. Uvid u najnovije istraživanje Deloittovog GMCS-a smatra se prvim istraživanjem koje naglašava uravnoteženi pristup potrošačima s obzirom na ponašanje prilikom korištenja svojih mobilnih uređaja. Prema anketi gotovo polovica US korisnika vjeruje kako koristi svoje uređaje previše, a taj broj iznosi više od 70% ispitanika dobne skupine 18-34. Kao rezultat toga, 47 % potrošača poduzima aktivne mjere za ograničavanje uporabe mobilnog telefona, poput čuvanja uređaja van vidokruga, isključivanje obavijesti ili povremeno isključivanje uređaja. Potrošači SAD-a gledaju svoje uređaje prosječno 47 puta dnevno te se upravo iz te činjenice očekuje kako će industrija nastaviti rasti. Nadalje, pružatelji mobilnih telekomunikacijskih usluga imaju priliku razviti dodatne usluge i aplikacije koje će potrošačima pomoći da budu odgovorni u korištenju svojih uređaja.

Telekom industrija, kao jedna od najbrže rastućih industrija u svijetu već koristi strojno učenje, umjetnu inteligenciju i Internet stvari u vidu poboljšanja svojih usluga korisnicima. Do danas, uloga umjetne inteligencije u telekomunikacijskom okruženju bila je ograničena na chat botove koji automatiziraju upite korisničkih službi, usmjeravaju kupce na odgovarajuće agente i usmjeravaju klijente s namjerom kupnje izravno prodavačima. Nadalje, umjetna inteligencija u mnogim drugim područjima telekomunikacija mreža pronalazi svoj put, kao što je to sredstvo za pomoć operaterima u poboljšanju učinkovitosti mreže, nižim operativnim troškovima i poboljšanju generalne kvalitete usluga i korisničkog iskustva. S obzirom da operateri prolaze tranziciju svoje mrežne arhitekture sa softverskim definiranim mrežnim i virtualizacijskim tehnologijama koje omogućuju automatizaciju, umjetna inteligencija će iskoristiti te sposobnosti za samodijagnosticiranje, samoizlječenje i samoorganiziranje mreže. Umjetna inteligencija korištenjem algoritama traži uzorke, otkriva i predviđa mrežne anomalije, omogućit će operaterima da proaktivno riješe probleme prije nego li se oni pojave i prije nego li oni pogode korisnike. Ova sposobnost prepoznavanja uzoraka od iznimne je važnosti s obzirom na mrežnu sigurnost jer će umjetna inteligencija pomoći u prepoznavanju sumnjivih aktivnosti povezanih s potencijalnim sigurnosnim prijetnjama, dopuštajući da mreža „poduzme akcije“ u realnom vremenu prije nego što utječe na performanse mreže. AI će omogućiti operaterima prikupljanje, pohranu i analizu podataka iz cijele korisničke baze kako bi postigli uvid u ponašanje u realnom vremenu. Upravo te informacije omogućiti će stvaranje personaliziranih ponuda, oglasa i usluga pretplatniku u

pravo vrijeme. Nadalje, kroz partnerstva s gradom, navedene informacije mogu se koristiti za javnu sigurnost, upravljanje prometom i upravljanjem lokalnim događanjima. Sve te informacije biti će nužne za operatore kako bi se postigla bolja iskorisćenost mrežnih resursa te omogućila prilagodba usluga na temelju potreba korisnika, okolišnih uvjeta i poslovnih ciljeva što rezultira boljom optimizacijom mreže. Jedna od najvećih prilika za telekomunikacijske tvrtke korištenjem AI jest mogućnost prikupljanja i procesiranja velikog obujma podataka povezanih s mrežom i njezinim uređajima kako bi se razumjela, optimizirala i poboljšala mrežna sposobnost kroz brže donošenje odluka.

3.3 Promjena poslovnih modela - AI i strojno učenje

U nastavku su specificirani načini kako AI i strojno učenje može pomoći poslovnim modelima telekomunikacija:

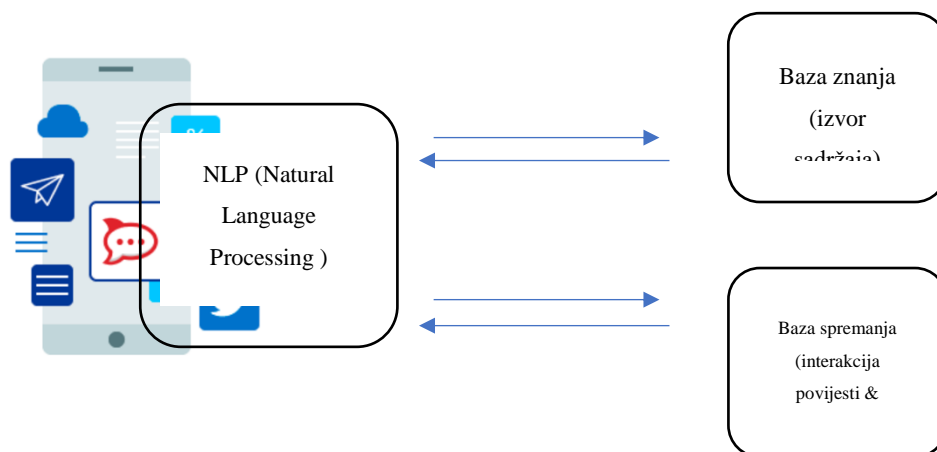
1. Poboljšanje korisničkog iskustva

Inteligentna analiza mreže okuplja više točaka podataka i pruža detaljan i djelotvoran uvid u čimbenike koji stoje iza mobilnog iskustva. Točnije, analiza pomaže telekomima da shvate koji korisnici imaju loše iskustvo uzrokovano mrežom te ono što je najbitnije, pomaže im da spriječe odlazak kod konkurenata. Na temelju znanja o podacima i izgradnjom platforme za AI telekomi mogu izvršiti procjenu iskustva korisnika, mjeriti indeks uspješnosti i predvidjeti potencijal za loša iskustva korisnika. Model analizira iskustvo iz perspektive korisnika, pružajući uvid u to kako se klijent osjeća u vezi iskustva. Kada model obradi podatke, on uči i pruža nekoliko manje značajnih, ali opet korisnih upozorenja o korisnikovom iskustvu.

2. Automatizacija usluga korisnicima

Ukoliko mobilni korisnik dođe do davatelja usluga, osim što ne žele čekati oni žele odgovore u danom trenutku. Iako bi telekom mogao udvostručiti veličinu svojih odjela za korisnike kako bi postigao brže stope odgovaranja, takvo rješenje nije izvedivo jer bi telekomi morali zaposliti više ljudi kako bi se vrijeme odgovora povećalo. No međutim, botovi imaju zamjensku ulogu za navedeno s obzirom da on može komunicirati s tisućama ljudi odjednom. Modeli umjetne inteligencije uče zašto klijenti dopiru do svojih pružatelja usluga te mogu predvidjeti kada će kupac uspostaviti kontakt, dopuštajući telekomu da proaktivno djeluje i pruži odgovor sada ukoliko kupac napravi prvi kontakt. U nekim slučajevima, chat botovi koji koriste AI mogu automatizirati odgovore na jednostavna pitanja i ukloniti

potrebu za ljudskom intervencijom za slična ili povezana pitanja. Korištenje AI chatbota pokazala se uspješnim načinom te je tako Elisa Estonija primijetila kako je moguće automatizirati 70% kontakata gdje je klijentu potreban brzi odgovor te je veoma rutinski zahtjev.



Slika 2. Automatizacija usluga

Natural Language Processing (NLP) Chatbot pronalazi načine kako pretvara govor ili tekst korisnika u strukturirane podatke, što se zatim koristi za odabir relevantnog odgovora.

Uz neke iznimke, AI rješenja za korisničke usluge mogu se podijeliti u dvije kategorije:

- a) Komunikacija sa službom za korisnike
- b) Angažiranje korisnika i personalizirano korisničko iskustvo

Rješavanje ili poboljšavanje navedenih kategorija predstavlja potencijalnu uštedu i povećanu učinkovitost za tvrtku.

AI komunikacija korisničkih usluga

Kako bi se problemi klijenata riješili na razini koja je nedokučiva agentima, AI algoritmi koji osnažuju komunikaciju s klijentima obrađuju veliku količinu podataka i interakcija. U telekomunikacijskom poslovanju postoji mnogo podataka različite prirode koji se mogu koristiti za obuku takvih algoritama. AI rješenja korisničkih usluga često su predstavljena kao chatbot sučelja, no to nije uvijek slučaj. Ponekad ti algoritmi djeluju u pozadini, što doprinosi ekonomičnosti rada odjela za usluge s korisnicima. Primjerice, analizom opsežnih podataka u pozadini pomaže CS agentu identificirati problem klijenta i pronaći ispravno rješenje. U nastavku navedeni su primjeri kako AI algoritmi imaju koristi od velikih američkih telekomunikacijskih tvrtki u području komunikacije s korisnicima:

-
- Djelovanje kao pristupnik između zahtjeva kupaca i centra za pomoć/live chat
 - Usmjerenje zahtjeva kupaca do odgovarajućeg agenta te usmjerenje potencijalnih kupaca s namjerom kupnje izravno prodajnom agentu
 - Analiziranje zahtjeva kupaca zajedno s mrežnim podacima kako bi se učinkovitije pronašlo rješenje za problem korisnika
 - Identificiranje „hot leads“ iz tisuća e-mailova i njihovo preusmjerenje prodavačima
 - Mogućnost da klijenti istražuju ili kupuju medijske sadržaje pomoću govora
 - Zabavni chatovi koji rade na izvornim platformama telekom operatera ili putem platforme Facebook Messenger

AI kao agent korisničke podrške

Telekomi često primjenjuju algoritme strojnog učenja kako bi se proces usluge kupcima bio troškovno učinkovitiji kojeg koriste tvrtke poput AT&T, Spectrum, CenturyLink i mnogi drugi.

AI virtualni pomoćnik Ask Spectrum-a pomaže korisnicima u rješavanju problema, informacijama o računu ili općenitim pitanjima o spektru usluga. Upiti korisnika kojima upravlja pomoćnik kreću se od identificiranja prekida usluga do naručivanja plaćenog sadržaja. On može pružiti korisnicima korisne savjete i veze do centra za pomoć ili ih u slučaju kompleksnijih zahtjeva uputiti na predstavnike Live Chat-a. Rezultat je vrijeme, koje agentima korisničke podrške omogućava da se bave složenijim upitima. Kako potencijalno spriječiti odlazak korisnika konkurenciji dokazuje primjer digitalne transformacije, odnosno uporaba AI u korisničkoj podršci. Tako je 2016. godine Centurylink implementirao svog AI asistenta Angie. Prema Harvard Business recenziji, Angie svaki mjesec obrađuje oko 30.000 poruka e-pošte i analizira „hot leads“ koji se zatim preusmjerava na relevantni odjel prodaje. Početni pilot pokazao je kako je Angie mogla ispravno protumačiti 99% e- poruka koje su obrađivane, dok onih 1% je proslijeđeno ljudskim agentima. AT&T, najveća svjetska telekomunikacijska tvrtka koristi AI za obradu svih „online chat interakcija“. Krajem 2016. godine AT&T uveo je Atticus, zabavni chat koji je komunicirao s korisnicima putem Facebook Messenger platforme. U travnju 2017. godine Vodafone je izdao novi chatbot TOBi koji pomaže klijentima putem live chata na stranici Vodafone UK. Kombinirajući umjetnu inteligenciju i unaprijed definirana pravila, TOBi simulira ljudske razgovore i odgovara na upite klijenata rješavanja problema, praćenja narudžbi i korištenja. Nedavno je TOBi unaprijeđen te je postigao mogućnost da pomogne korisnicima pri kupnji SIM only

plans. U MindTitanu također vidimo potencijal za korištenje lokacije i mrežne analitike za poboljšanje korisničke usluge. Ukoliko za primjer, klijent s određene lokacije ima problem, algoritmi mogu provjeriti analitiku mreže kako bi identificirali potencijalne probleme ili nedostatke u tom području. Rezultat toga jest da predstavnik službe za korisnike pomaže u rješavanju problema zahvaljujući znanju o tome što bi moglo biti ispravno rješenje.

3.3.1 Iskustvo prodaje i personaliziranog korisnika

Osim usluge chatbot-ova za korisnike i sustava za usmjeravanje upita, AI može pomoći telekomunikacijskim tvrtkama da poboljšaju zadržavanje klijenata i ostvare veću zaradu po korisniku. U nastavku predstavljeni su slučajevi kada korisnosti uporabe algoritama strojnog učenja:

- Izrada personaliziranih preporuka na temelju obrazaca ponašanja korisnika i njegovih postavki sadržaja
- Procjena paketa poziva i podataka koji najbolje odgovara različitim korisnicima, povećavajući uspješnost prodaje
- Otkrivanje i rješavanje potencijalnih problema za klijente čak i prije nego li su oni očiti krajnjem korisniku
- Analiziranje društvenih medija, pokrivenost branda i sentimenata u vidu dobivanja saznanja o klijentima, što ih pokreće- koje usluge a što ih tjera da odu

Također, predstavljena su tehnološka AI rješenja koja mogu preporučiti najbolja potencijalna rješenja za problem povezanosti ili druge vrste problema. Tako je Comcast, vodeća tvrtka za emitiranje i kabelsku televiziju u svijetu po prihodima lansirao glasovni daljinski upravljač koji korisnicima omogućuje interakciju sa svojim Comcast sustavom putem prirodnog govora. Također, telekomunikacijska tvrtka koristi AI za obradu velikih količina metapodataka i korištenje strojnog vida kako bi korisnicima ponudili novi relevantni sadržaj. Mnogo sustavi za preporuku temelje se na optimizaciji NBO (sljedeće najbolje ponude) i optimizaciji NBA (sljedeće najbolje akcije). Metodologija NBA može se primijeniti i za otklanjanje pogrešaka kod nekih korisnika, algoritmi mogu preporučiti najbolja potencijalna rješenja za problem povezanosti ili druge vrste problema.

Nadalje, još jedna od upotrebi AI-a u telekomunikacijskom poslovanju je povezivanje kupaca s najboljim paketima podataka. Algoritmi za samostalno učenje akumuliraju uvid u

to koji paketi odgovaraju različitim vrstama kupaca, smanjujući opterećenje operatora poziva i čineći proces prodaje daleko učinkovitijim.

Analitika mreže koju pokreće AI može se iskoristiti za sljedeće:

- AI sustav može ponovno pokrenuti ćelije na temelju njihovog ponašanja, npr. Ako se ne povezuju s mrežom
- Algoritmi mogu ukazati na dijelove mreže za koje su potrebna ulaganja i koji bi proizveli najviši ROI
- Mrežni operatori mogu koristiti AI za identifikaciju dijelova mreža s velikim brojem korisnika koji bi imali koristi od poboljšanja mreže, što dugoročnije donosi veću dobit
- Optimizacija ponašanja mreže na temelju podataka o vremenu, kretanjima i podataka u realnom vremenu
- Povećanje iskoristivosti mreže i zadovoljstvo korisnika kroz dinamičku raspodjelu resursa

Iz perspektive kupaca, posjedovanje AI vođenog agenta uključenog u proces može značiti znatno bolje iskustvo usluge. Umjesto 20 minuta razgovora s predstavnikom službe za korisnike, problem klijenata mogao bi se riješiti algoritmom u roku od nekoliko sekundi, naravno ovisno o prirodi i složenosti problema. U konačnici, ovaj pristup detekcije i otklanjanje problema dovodi do većeg zadovoljstva klijenata i konačno do zadržavanja. Nadalje, mreže s omogućenom AI inteligencijom sposobne su za samoanalizu i samooptimizaciju, a rezultat je agilnost i preciznost.

3.3.2 AI trendovi

S obzirom da AI transformira svakodnevni život i poslovanje, neophodno ga je primijeniti kako bi se optimizirale interne i eksterne operacije te se donosile kvalitetnije poslovne odluke. Prema nedavnoj studiji Deloittea, 82% tvrtki koje su već investirale u umjetnu inteligenciju imaju financijski povrat na svoja ulaganja. Za tvrtke među svim industrijama

srednji povrat od ulaganja od kognitivnih tehnologija je 17%.⁵ Nadalje, u nastavku su prikazana 4 AI trenda koji će transformirati telekom industriju u 2019. godini⁶.

1. Optimizacija mreže

AI predstavlja ključan aspekt u pomoći CSP-ovima u izgradnji samopromjenjivih mreža (SONs), prema kojem operateri imaju mogućnost automatskog optimiziranja kvalitete mreže na temelju informacija o prometu po regijama i vremenskoj zoni. Umjetna inteligencija u telekomunikacijskoj industriji koristi napredne algoritme za traženje uzoraka unutar podataka što omogućuje otkrivanje i predviđanje mrežnih anomalija te omogućava proaktivno djelovanje na probleme prije nego li korisnik postane nezadovoljan. [12]

Pravi primjer primjene je postavila Nokia koja je pokrenula vlastitu AVA platformu temeljenu na strojnom učenju, rješenje koje upravlja mrežom temeljenom na cloudu za bolje upravljanje kapacitetom i predviđanjem degradacija usluga na stranicama do sedam dana unaprijed.

2. Prediktivno održavanje

Korištenjem podataka AI prediktivna analitika uvelike pomaže telekomunikacijama u pružanju kvalitetnije usluge. [13] Svojim sofisticiranim algoritmima i tehnikama strojnog učenja predviđa buduće rezultate poznajući povijesne podatke. Uvidom u podatkovne sustave, telekomunikacijski stručnjaci mogu pratiti stanje opreme, predvidjeti neuspjeh i proaktivno riješiti probleme s komunikacijskim hardverom, kao što su ćelijski tornjevi, dalekovodi, poslužitelji podatkovnih centara, pa čak i set-top kutije u kućanstvu korisnika. Primjer inovativnosti jest rješenje tvrtke AT&T koja koristi AI kako bi podržala svoje održavanje, tvrtka testira bespilotne letjelice kako bi proširila pokrivenost svoje LTE mreže i iskoristila analizu video podataka snimljenih kako bi omogućila tehničku podršku i održavanje infrastrukture svojih ćelijskih tornjeva.

3. Virtualni asistent

Razgovorne platforme poznate kao virtualni asistenti uspješno su automatizirale proces komunikacije s korisnikom tako da predviđaju smanjenje poslovanja za čak 8 milijardi dolara u narednih 5 godina. Razlog zašto se telekomu okreću virtualnim asistentima leži u

⁵ <https://deepsense.ai/ai-trends-2019/>

⁶ <https://becominghuman.ai/4-ai-trends-that-will-transform-the-telecom-industry-in-2019-1bf0d58637cd>

velikom broju zahtjeva za podrškom za instalaciju, postavljanje i rješavanje problema te održavanje. Korištenjem umjetne inteligencije telekomi mogu implementirati samouslužne mogućnosti koje upućuju korisnike kako instalirati i upravljati vlastitim uređajima.

4. Automatizacija robotskih procesa (RPA)

Robotska procesna automatizacija oblik je tehnologije automatizacije poslovnih procesa koji se temelji na AI. RPA može donijeti veću učinkovitost telekomunikacijskim funkcijama dopuštajući telekomunikacijskim tvrtkama da lakše upravljaju svojim back office poslovima i velikim količinama procesa koji se ponavljaju i temelje na pravilima. Racionalizacijom izvršavanja nekada složenih i dugotrajnih procesa, kao što su naplata, unos podataka, upravljanje radnom snagom i ispunjenje narudžbi, RPA oslobađa osoblje CSP-a za posao s većom dodanom vrijednošću.

Navedeni AI trendovi ukazuju na primjenu umjetne inteligencije u telekomunikacijskoj industriji, pomažući CSP-ovima da upravljaju, optimiziraju i održavaju svoju infrastrukturu i operacije podrške korisnicima. Optimizacija mreže, virtualni asistenti, prediktivno održavanje i RPA primjeri su kako umjetna inteligencija ima veliku primjenu u transformaciji poslovanja.

3.4 Rast prihoda

Unatoč eksponencijalnom rastu korištenja mreže, globalni telekomunikacijski prihod raste samo za 1,1 % u 2017. godini u odnosu na prethodnu godinu, prema novom izvješću IHS Markit⁷. [14] Prema posljednjem istraživanju Statista tržište telekomunikacijskih usluga, koja uključuje usluge fiksne mreže i mobilne usluge imala je vrijednost od oko 1,4 bilijuna američkih dolara u 2017. godini, a predviđa se kako će do 2020. godine porasti na skoro 1,46 bilijuna američkih dolara. Najveća tržišta telekomunikacijskih usluga su u regiji Azije/Pacifika, Europe i Sjeverne Amerike. Prevladavajuće mobilne i bežične tehnologije porasle su u posljednjih 15 godina, te se očekuje kako će tržište i dalje rasti s obzirom da se broj mobilnih veza širom svijeta očekuje do 9 milijardi do 2020. godine, što je u odnosu na 2009

⁷ <https://technology.ihs.com/598720>

godinu otprilike udvostručeno. Bežična veza također predstavlja ključno tržište za telekomunikacijske tvrtke. Ukupna potrošnja telekomunikacijskih bežičnih podataka diljem svijeta očekuje se do 2019. godine kada će ono iznositi gotovo 500 milijardi američkih dolara.

4. Metode predikcije

Logistička regresija modelira vjerojatnosti klasifikacije problema s dva moguća ishoda te se smatra kao proširenje modela linearne regresije za probleme klasifikacije. Svoju primjenu logistička regresija pronalazi u opisivanju podataka i objašnjenju odnosa između jedne ovisne binarne varijable i jedne ili više nominalne, ordinalne, intervalne ili neovisne varijable na razini odnosa. Kao i sve regresijske analize, logistička regresija je prediktivna analiza. Pogodna je za rješavanje problema kategoričkih varijabli poput onih demografskih (bračni status, lokacija, zanimanje itd..) U nastavku su predstavljeni prednosti i nedostaci uporabe logističke regresije.

Nedostaci

Model linearne regresije funkcionira za regresiju, no ne uspijeva provesti klasifikaciju. Razlog tome leži u činjenici, uzmimo za primjer dvije klase, jednu označavamo s 0, drugu s 1 i koristimo linearnu regresiju. Tehnički na ovaj način to uspijeva te većina programa linearnog modela dostavlja težinu, no međutim postoji nekoliko problema s ovim pristupom:

Linearni model ne ispisuje vjerojatnosti, ali klasu tretira kao brojeve (u ovom slučaju, 0 i 1) i odgovara najboljem **hyperplane** (za jednu osobinu to je linija) koja minimizira udaljenosti između točaka hiper-ravnine. Stoga, upravo iz činjenice kako ona jednostavno interpolira između točaka i ne može se tumačiti kao vjerojatnosti. Nadalje, linearni model također ekstrapolira i daje vrijednosti ispod nule i iznad jedan. To upravo ukazuje kako možda postoji kvalitetniji pristup u klasifikaciji.

Obzirom da predviđeni ishod nije vjerojatnost, već linearna interpolacija između točaka, ne postoji značajan prag prema kojem se može razlikovati jedna klasa od druge. Linearni modeli ne obuhvaćaju probleme klasifikacije s više razreda, iako razredi možda nemaju smisleni poredak linearni model prisilio bi čudnu strukturu na odnos između značajki i predviđanja klase. Što je viša vrijednost značajke s pozitivnom težinom, to više doprinosi predviđanju klase s većim brojem, čak i ako klase koje imaju sličan broj nisu bliže od ostalih klasa.

Mnoge prednosti i nedostaci modela linearne regresije također se primjenjuju na model logističke regresije. Logistička regresija, iako često korištena bori se sa restriktivnom izražajnošću s obzirom da se interakcije dodaju ručno nasuprot onih modela koje imaju bolje prediktivne performanse. Također, tumačenje je teže s obzirom da je interpretacija težina

multiplikativna a ne aditivna. Nadalje, logistička regresija može patiti od potpunog odvajanja, ukoliko postoji obilježje koje bi savršeno razdvojilo dva razreda, model logističke regresije više se ne može trenirati. Razlog tome leži u činjenici kako se težina za tu značajki ne bi približavala, jer bi optimalna težina bila beskonačna. Problem potpunog razdvajanja može se riješiti uvođenjem penalizacije težine ili definiranjem prethodne razdiobe vjerojatnosti.

Prednosti logističke regresije očituju se u činjenici kako on nije samo model klasifikacije već i daje vjerojatnosti. Tu leži velika prednost u odnosu na druge modele s obzirom da oni mogu dati samo konačnu klasifikaciju. Velika razlika očituje se u podatku kako instanca ima 99% vjerojatnosti za klasu u usporedbi sa 51%. Također ona se može proširiti i od binarne klasifikacije do klasifikacije u više klasa, te se tada ona naziva multionominalna regresija.

Modeliranje gubitka važno je za održavanje profitabilnih odnosa sa klijentima na zasićenom tržištu. Model gubitka predviđa vjerojatnost odlaska kupaca. Upravo ti podaci važni su za usmjeravanje ponuda zadržavanja ključnim klijentima te učinkovito korištenje marketinških resursa. Prevladavajući pristup razvoju modela odlijeva, nadziranog učenja ima važna ograničenja, on ne dopušta marketinškom analitičaru da uzme u obzir ciljeve i ograničenja planiranja kampanje tijekom izgradnje modela. Upravo stvaranje modela odlijeva povećava učinkovitost konačnog modela za marketinšku podršku odlučivanja. U nastavku predstavljeni su uobičajeni razlozi za odljev i kako tvrtke mogu na vrijeme spriječiti njihov odlazak⁸.

⁸ <https://www.tibco.com/blog/2013/04/10/data-analysis-to-reduce-churn-in-telecom/>
<http://thinkapps.com/blog/post-launch/customer-churn-most-important-metric/>

-
1. Cijena promocija konkurenata doprinose privlačenju kupaca da pređu na konkurenta
 2. Kvaliteta usluge odnosno nedostatak povezivanja s korisnikom može dovesti kupca do operatera koji ima veću mrežnu pokrivenost
 3. Nedostatak korisničke usluge podrazumijeva spor ili bez odgovora na pritužbe korisnika povećava vjerojatnost odlaska klijenta
 4. Sporovi o naplati
 5. Nova konkurencija koja ulazi na tržište
 6. Konkurencija koja upoznaje tržište s novim proizvodom ili tehnološkim napretkom

Štoviše, prema globalnoj provedenoj anketi potrošača za 2011. godinu otkriva kako je odljev osobito visok u komunikacijskoj industriji te da će potrošači na tržištima u razvoju vjerojatnije zamijeniti brand od onih na razvijenijim tržištima. Najnoviji, posljednji indeks zadovoljstva u UK tržištu, objavljen 2018. godine od strane Instituta za službu za korisnike ukazuje kako je zadovoljstvo potrošača u Velikoj Britaniji 77,9/100. Telekomunikacije su postigle 74,3 bodova što ga čini drugom najnižom vertikalnom ocjenom s obzirom da je samo sektor prometa bio lošiji sa 72,5 bodova. Novo izvješće o brzom uvidu TM Foruma pod nazivom „Inspire loyalty with customer lifecycle management“ pod sponzorstvom BriteBill, tvrtke koja se bavi istraživanjem i informacijama ukazalo je kako je *postpaid* odljev trenutno kreće od 5-32% godišnje. Iako je teško odrediti prosječan iznos troška odljeva s obzirom na činjenicu kako prosječni mobilni operater na zrelom tržištu troši 15-20% prihoda na uslugu akvizicije i zadržavanje, u usporedbi s prosječnom potrošnjom na infrastrukturu (mrežu i IT) od samo 15 % prihoda.⁹

4.1 Odlazak korisnika

U životnom ciklusu upravljanja klijentima, gubitak korisnika odnosi se na odluku kupca o prestanku poslovnog odnosa s telekom kompanijom. Lojalnost kupaca i gubitak kupaca uvijek čine 100%. Ukoliko tvrtka ima 60% lojalnosti, njihov gubitak ili stopa odljeva klijenata je 40%. Prema pravilu 80/20 o profitabilnosti kupaca, 20% kupaca ostvaruje 80%

⁹ <https://www.computerweekly.com/blog/The-Full-Spectrum/How-churn-is-breaking-the-telecoms-market-and-what-service-providers-can-do-about-it>

prihoda.¹⁰ Stoga, vrlo je važno predvidjeti korisnike koji će vjerojatno u odustati od poslovnog odnosa u kojem jesu i čimbenike koji utječu na odluke kupaca.

Odljev korisnika, engl. Churn predstavlja prestanak poslovanja s tvrtkom ili uslugom i predstavlja gubitak klijenata ili kupca. U nastavku predstavljen je koncept predviđanja odlaska kupaca pomoću telekomunikacijskog skupa podataka. Predstavljena je logistička regresija, stablo odlučivanja i Random Forest, prediktivni modeli koji će dati uvid organizacijama koji segmenti ponajviše utječu na odlazak klijenata i na koje segmente se organizacije moraju fokusirati kako bi smanjile postotak odlaska klijenata te pronašli na temelju analize najoptimalnije rješenje. Predstavljen je set podataka na kojem se temelji analiza s ciljem: a) potvrđivanja ili pobijanja hipoteze, b) opisivanja i predstavljanja korištenih prediktivnim modela u rudarenju podacima, c) definiranje varijabli koje nisu bitne za prediktivni model, d) modeliranje podataka prediktivnim tehnikama Stabla odlučivanja, Logističke regresije i Random Foresta, e) procjena pouzdanosti modela

¹⁰ <http://www.treselle.com/blog/customer-churn-logistic-regression-with-r/>

5. Metodologija istraživanja

U ovom dijelu obrazložena je metodologija istraživanja koja uključuje ciljeve istraživanja, hipotezu, grafički prikaz rezultata istraživanja te interpretaciju provedenog istraživanja.

5.1 Ciljevi istraživanja

- Otkriti koji će klijenti vjerojatno otkazati pretplatu na usluge koje koriste na temelju načina na koji je koriste
- Analizirati i izdvojiti koje značajke igraju ulogu u odljevu kupaca
- Provesti pre-procesuiranje podataka
- Partitioniranje populacije na skup za učenje i skup za treniranje podataka
- Primjena logističke regresije, stabla odlučivanja i Random Foresta na skupu za učenje i skupu za testiranje
- Procjena pouzdanosti modela
- Analizirati postoji li odnos i povezanost između spola i odljeva

5.2 Hipoteze istraživanja

Na osnovi dosadašnjih istraživanja postavljena je sljedeća hipoteza:

H1....Može li se procijeniti koje značajke i u kojoj mjeri ponajviše utječu na odlazak klijenata u telekomunikacijskoj industriji

5.3 Metoda istraživanja

Sukladno predstavljenim ciljevima i hipotezi, u radu su prikupljeni podaci iz sekundarnih izvora. Sekundarni podaci uključivali su znanstvena istraživanja na temu digitalne transformacije, disruptivne inovacije, tipovi učenja s obzirom na tip podataka, telekomunikacijska industrija i nadolazeći trendovi, uporaba strojnog učenja, automatizacija usluga. U ovom djelu prikazano je predviđanje odlaska korisnika na skupu podataka u telekomunikacijama. Kroz logističku regresiju, stablo odlučivanja i Random Forest model za koje je preliminarno potreban R (besplatni programski jezik i softversko okruženje za

statističku računalnu obradu i grafiku koju podržava Zaklada za statističku obradu) i RStudio [44] (nenaplatna i open-source integrirana razvojna okolina (IDE) za R, programski jezik za statističko računanje i grafiku) predviđa se ponašanje kako bi se zadržali klijenti. Svrha rada jest analizirati sve relevantne podatke o klijentima kako bi poduzeća učinkovitije mogla definirati strategiju i programe zadržavanja korisnika. Skup podataka sadrži 14,064 redaka podataka, u 22 kolumne prema kategorijama:

5.3.1 Obilježja klijenata

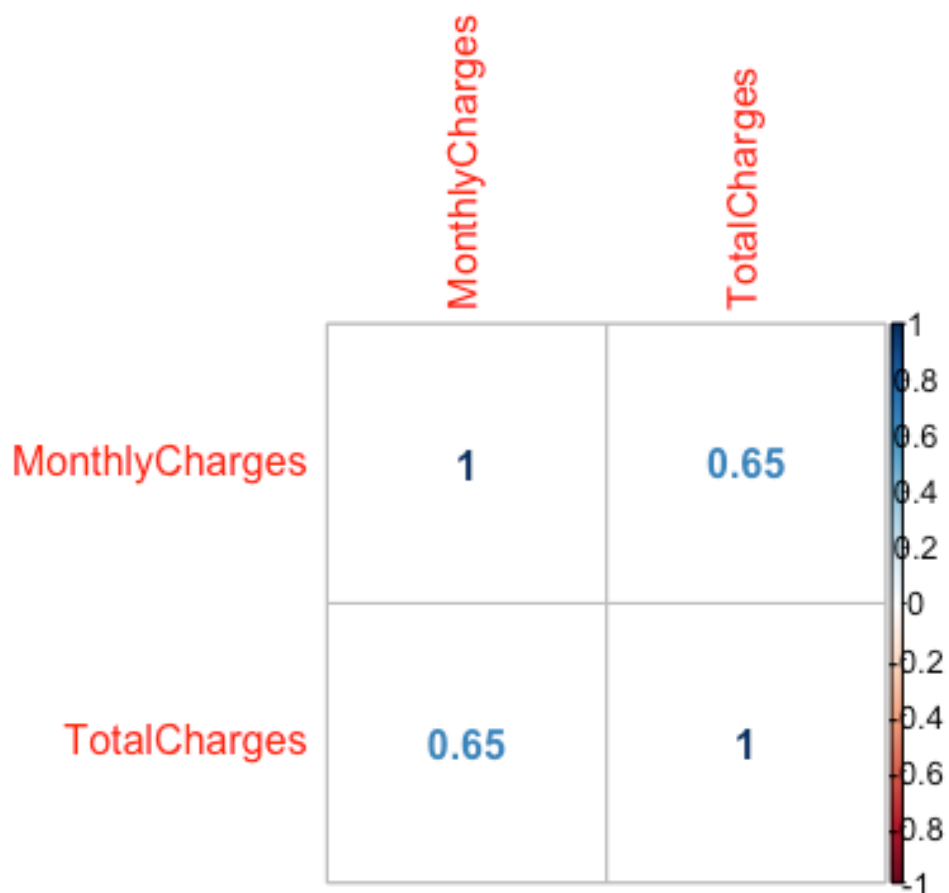
Korisnikov ID, Spol, Dob (mlađe, starije), Partner (ima bi korisnik partnera ili ne), Uzdržavanje (jeli korisnik ovisan financijsko o nekome ili nije), vrijeme (broj mjeseci korisnika koliko je proveo u tvrtki), telefonske usluge (ima ili ne), Višestruke linije (ima li više linija ili ne ili nema mobilne usluge), Internet usluge (davatelj usluge- DSL, Optički kabel, Ne), Sigurnost na mreži (ima li korisnika online sigurnost ili ne – Da, Ne, Nema internetske usluge), Online Backup (bilo da klijent ima rezervnu kopiju na mreži ili ne (Da, Ne, Nema internetske usluge)), Zaštita uređaja (bilo da klijent ima zaštitu uređaja ili ne (Da, Ne, Nema internetske usluge)), Tehnička podrška (bilo da korisnik ima tehničku podršku ili ne (Da, Ne, Nema internetske usluge)), Streaming (bilo da korisnik ima streaming TV ili ne (Da, Ne, Nema internetske usluge)), Ugovor (Ugovorni rok kupca (mjesec-mjesec, jedna godina, dvije godine)), Naplata bez papira (bilo da klijent ima naplatu bez papira ili ne (Da, Ne)), Način plaćanja (način plaćanja klijenta (elektronička provjera, poslana potvrda, bankovni prijenos (automatski), kreditna kartica (automatski)), Mjesečna naknada (iznos koji se naplaćuje korisniku mjesečno), Ukupni troškovi (ukupan iznos koji se naplaćuje klijentu), najčešći uzrok frustracije korištenjem službe za korisnike (Nedostatak točnosti, nedostatak učinkovitosti, Sporost pri rješavanju problema) te Odlijev klijenata kao posljednja najrelevantnija značajka opisuje odlazak korisnika (Da, Ne)

Nadalje, prije nego li se provede detaljnija analiza, ključno je identificirati i ekstrahirati značajke kako bi nestrukturirane podatke pretvori u strukturirani set. Ono što je neophodno u pre-procesuiranju s obzirom na set podataka koji planiramo analizirati jest ukloniti sve retke s vrijednostima koje nedostaju, ukoliko ih ima. Također, odgovori korisnika „Nema internetske usluge“ zamijenjen je s ne odgovorom kao i u šest kolona: Online sigurnost, Online Backup, Sigurnost uređaja, Tehnička podrška Streaming TV. Ukoliko sagledamo vrijeme zadržavanja korisnika u telekomunikacijskoj tvrtki može se primijetiti kako se ti podaci također mogu strukturirati kako bi daljnja analiza bila preciznija te se tako isti ti


podaci daju grupirati u pet sljedećih skupina; „0-12 mjeseci“, „12-24 mjeseci“, „48-60 mjeseci“ te „>60 mjeseci“. Sukladno navedenim primjerima grupiranja podataka u vidu dobivanja strukturiranog seta grupirani su i ostali podaci.

5.3.2 Korelacija numeričkih varijabli

Koeficijent korelacije opisuje smjer i jakost linearne veze između dvije varijable, ali ne može zaključivati o uzročno posljedičnom odnosu promatranih varijabli. Nadalje, u nastavku u setu podataka postoji korelacija numeričkih varijabli, posljedično Mjesečnih plaćanja i Ukupnih Plaćanja stoga je jedan od njih uklonjen iz modela.



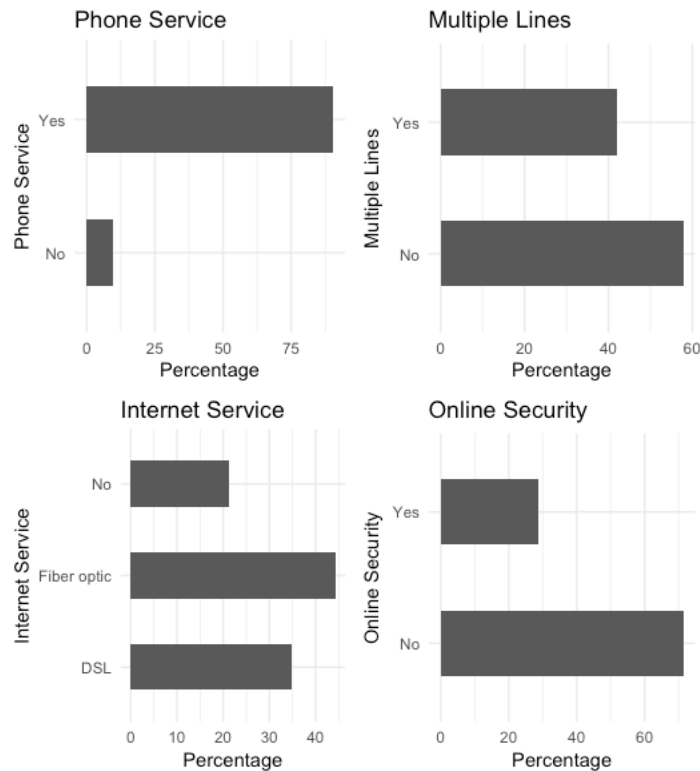
Grafički prikaz 1. Korelacijski prikaz numeričkih varijabli



Grafički prikaz 2. Grafički prikaz kategoričkih varijabli

Grafički prikaz kategoričkih varijabli ukazuje nam na postotak spola, dobi, partnerstva i uzdržavanja u setu podataka. Set podataka sadrži 50% muškaraca i žena, 80 % su starije dobi, dok njih manje od 20% su mlađe. Također, preko 50% ispitanika ima partnera, dok njih nešto manje od 50% nema. Uzdržavanih članova ima 30%, a njih neuzdržavanih 70%.

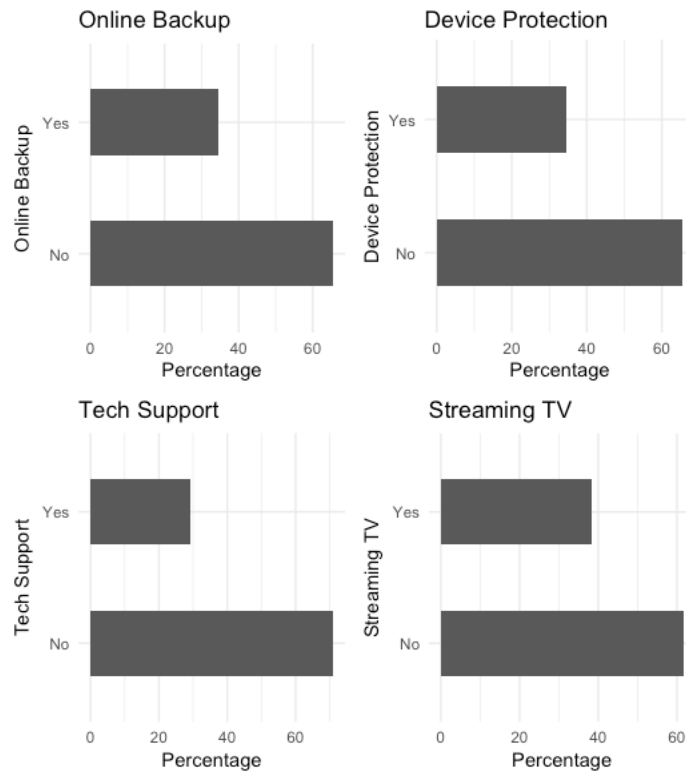
Iz već letimične analize uzorka sasvim je jasno kako smo zahvatili populacijski segment koji odgovara stvarnom stanju na tržištu s kojim se telekom operateri svakodnevno bave. Naime, svaki od navedenih segmenata korisnika, kada se oni još dodatno preklope ako se gledaju spol + dob + partner ili ne pokazuju koliko su loženi modeli kako predvidjeti što će i kako taj korisnik napraviti i reagirati. Kako ovdje gledamo samo korisnikove populacijske oznake treba uzeti u obzir da bi bilo idealno kada bi se još njemu mogla pribrojiti kategorija prema visini osobnih prihoda, visini prihoda kućanstva, mjestu stanovanja.



Grafički prikaz 3. Grafički prikaz kategoričkih varijabli

U setu podataka, preko 85 % ispitanika koriste usluge mobilnih uređaja, dok njih 15% ne koriste. Gotovo 60% korisnika ima nekoliko linija uređaja, dok njih 42% nema. Također, 22% ispitanika nema usluge interneta, dok optički kabel koristi njih 44% korisnika, a DSL ima 34% korisnika. Sigurnost na mreži nema preko 70% korisnika, dok njih gotovo 30% ima.

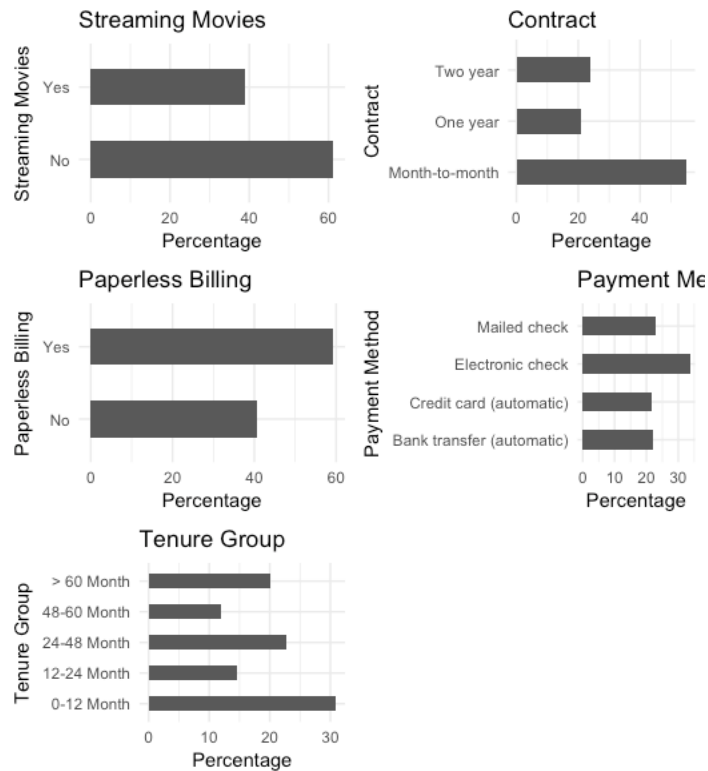
Kada se gleda struktura korisnika odnosno koju od usluga koriste kao što je navedeno u našem uzorku sasvim je jasno da o tome kako će se korisnik ponašati prije svega ovisi o nekim dijelovima modeliranja njegova ponašanja koje je uvjetovano prijašnjim iskustvom, ali prije svega njegovim stvarnim potrebama koje on iskazuje primjerice da li ima ili nema usluge u mobilnoj telefoniji, da li koristi Internet.



Grafički prikaz 4. Grafički prikaz kategoričkih varijabli

Online Backup nema preko 60% korisnika, dok preko 30% korisnika ih ima. Nadalje, koliko je njihov uređaj zaštićen govori podatak kako njih 65% korisnika ga nema, dok njih 35% posjeduje osiguranost uređaja. Tehničku podršku ima samo 30% ispitanika, dok većina, njih 70% nema. Uslugu Streaming TV-a koristi gotovo 40% korisnika, dok 60% korisnika nema uključenu uslugu.

U segmentu upravljanja dijelovima usluga koje imaju pojedini korisnici već je na prvi pogled jasno kako korisnici zapravo ne pridaju pažnju svojim podacima i da bi to u slučaju nekog neželjenog ishoda mogao rezultirati problemima te telekome. Upravo je iz ovih podataka vidljivo koliko zapravo korisnici telekomunikacijskih usluga zapravo uopće nemaju ideju što ih čeka i da impulsno koriste svoje usluge, a ne razmišljaju o posljedicama.



Grafički prikaz 5. Grafički prikaz kategoričkih varijabli

60% korisnika ne koristi usluge Streamanje Filmova, te gotovo 40% njih koristi. Kada su u pitanju ugovori, ugovor na dvije godine ima više od 22% korisnika, jednu godinu ugovora ima 20% ispitanika, a nešto više od pola korisnika, njih 58% ima mjesečni ugovor s tele operaterom. Nadalje, papirnate račune koristi 60% korisnika, dok njih 40% ne koristi. Oblik plaćanja korisnika putem maila ima 23% korisnika, 33% korisnika plaća elektroničkim računom, karticom plaća 22% korisnika, a transakcijom putem banaka plaća 22% korisnika.

Broj mjeseci koje je korisnik ostao u Telco telekomunikacijama 0-12 mjeseci je 30% korisnika, njih 14% ispitanika je ostalo od 12-24 mjeseci, 24-48 mjeseci zadržalo se 23% korisnika, 48-60 mjeseci zadržalo se 13% korisnika, dok se najviše zadržalo samo njih 20% u više od 60 mjeseci.

Razdvajanje podataka u skupove za treniranje i testiranje neophodan je dio procjene modela rudarenja podataka. Nadalje, većina podataka koristi se za treniranje, a manji dio podataka koristi se za testiranje. Analitika omogućava nasumično uzimanje podataka kako bi se osiguralo da su skupovi za testiranje i treniranje slični. Koristeći slične podatke minimiziraju se učinci nepodudarenosti podataka i bolje razumijevanje karakteristika

modela. Podjela podataka predstavlja proces logičke i/ili fizičke podjele podataka te sukladno skupu, 70% podataka odlazi na testiranje, dok na treniranje odlazi 30% podataka u setu.

5.4 Logistička regresija

U vidu predstavljanje modela logističke regresije set podataka je podijeljen na dio za treniranje i dio za testiranje. Nadalje, prije nego li započnemo s model logističke regresije *Steowise* metodom iz modela uklanjamo varijable koje nisu bitne za predikciju.

Primjenjujemo model na testnom skupu na kojem računamo vjerojatnost odljeva korisnika. Ukoliko je vjerojatnost odljeva veća od 0.5, osobu tretiramo kao da se odljev dogodio, u suprotnom osoba nije otkazala usluge koje koristi.

Stvarno/Predikcija	NE	DA	UKUPNO
NE	2876	221	3097
DA	550	571	1121
UKUPNO	3426	792	4218

Grafički prikaz 6. Prediktivni model Logistička regresija

Ukoliko sagledamo rezultate, možemo uvidjeti kako je model logističke regresije ukazao sljedeće:

- Za 221 ljudi reklo da će se dogoditi odljev korisnika, a nije se dogodio
- Za 550 ljudi koji su otišli, model je predvidio da se neće dogoditi odljev
- Za 2876 ljudi koji nisu otišli model je predvidio kako neće otići
- Za 571 ljudi koji su otišli, model je predvidio kako će se dogoditi odljev


Nadalje, kako bismo mogli provjeriti djelotvornost prediktivnog modela računat ćemo Lift krivulju koja nam ukazuje na navedeno. Za početak potrebno je odgovore Da i Ne pretvoriti u numeričku varijablu 0 i 1 i korisnike sortirati silazno po vjerojatnosti odljeva kako bi izračunali kumulativni postotak odljeva korisnika. Kako bi dočarali rezultat, predstaviti ćemo ga na primjeru. Ukoliko kontaktiramo 400 korisnika s najvećom vjerojatnosti odljeva (za koje je model predvidio odljev) kontaktirat ćemo 303 korisnika

koji su otišli što je 27% od ukupnog broja odljeva korisnika. S obzirom da su složeniji modeli često precizniji od onih jednostavnih, potrebno je odrediti željenu točnost modela. Ona za navedenu konfuzijsku matricu iznosi: 81,72% .

5.5 Stablo odlučivanja

Stablo odlučivanja kao poznata metoda klasifikacije ima primjenu na setu utreniranih podataka u vidu stjecanja potencijalnog uvida u vrijednost seta. Glavni dijelovi stabla odlučivanja su: izvorni čvor (engl. *root node*), grane (ogranci) te granični čvor (engl. *leaf nodes*). Svaki čvor označava ishod, a svaki ogranak ima oznaku klase. Kao metoda rudarenja podacima često se prilikom analize kombiniraju s metodom klasteriranja. Prema Panian i Klepac osnovna zadaća im je određivanje varijabla i njihovih vrijednosti koje determiniraju određeni skup pojava. Nadalje, ova metoda može poslužiti prilikom segmentiranja tržišta pri čemu su rezultat analize lako čitljiva pravila segmentacije. Pored toga oni svoju primjenu pronalaze u razvrstavanju, predviđanju, procjeni vrijednosti, grupiranju, opisivanju podataka te vizualizaciji.

Prije nego li predstavimo prednosti i nedostatke stabla odlučivanja kao prediktivni model, u nastavku je na testnom modelu predstavljeno stablo odluke, kao i rezultati dobiveni modelom. Rezultati će ukazati vjerojatnost odljeva korisnika, ukoliko je vjerojatnost veća ili jednaka 0.5, osobu će proglasiti model odljevom. Važno je napomenuti kako je uključen minimalni broj opservacija u graničnom čvoru 1000 te je dana prosudba o vrijednosti svakog elementa.



Grafički prikaz 7. Stablo odlučivanja

Iz priloženog, možemo primijetiti kako je varijabla Ugovor najvažnija varijabla u predikciji odljeva korisnika. Ukoliko je ugovor sklopljen na mjesečnoj razini, osoba ili ima DSL ili nema Internet uslugu u razdoblju 0-12 mjeseci, model je procijenio da su šanse za churn 20,2%.

Oni koji nemaju internetsku uslugu, model je predvidio kako njih 25,6 % će otići od operatera, dok njih 74,4 % neće, u uzorku od 551 klijenta. U uzorku od 954 klijenta, korisnici koji imaju DSL, njih 45,8 % će otići, dok njih 54,2% neće. Prema modelu, na 997 ljudi model je predvidio za klijente koji imaju ugovor na više od 12 mjeseci kako njih 79,8 % neće churnati, dok njih 25,6% će otići od operatera. Ako pogledamo uzorak temeljen na najveći broj klijenata, njih 1091, samo 0,7% klijenata će otići, dok njih 99,3% neće. No, ti klijenti su na načinu plaćanju na mjesečnoj razini, s ugovornom obvezom od dvije godine mjesečnim izdacima, plaćanju kreditnim karticama, bankovnom transakcijom (automatskom) ili mail računom. Evaluacija seta podataka predstavljena je na 30% koji odlaze na testni skup.

Konfuzijska matrica kao tablični prikaz za opisivanje izvedbi klasifikacijskog modela na skupu testnih i treniranih podataka koje ukazuju na poznate prave vrijednosti. Konfuzijska matrica je za model stabla odlučivanja ukazala sljedeće:

Stvarno/Predikcija	NE	DA	UKUPNO
--------------------	----	----	--------

NE	2862	235	3097
DA	671	450	1121
UKUPNO	3533	685	4218

Grafički prikaz 8. Prediktivni model

- Za 2862 ljudi koji nisu otišli model je predvidio kako se odljev neće dogoditi
- Za 235 ljudi koji nisu otišli model je predvidio da će otići
- Za 671 koji jesu otišli, model je predvidio kako neće otići
- Za 450 ljudi koje je otišlo, model je predvidio kako će otići

S obzirom da su složeniji modeli često precizniji od onih jednostavnih, potrebno je odrediti željenu točnost modela. Ona za navedenu konfuzijsku matricu iznosi: 78,5% .

5.5.1 Prednosti

Prednost stabla odlučivanja u odnosu na druge metode rudarenja podacima očituje se u jednostavnosti korištenja i razumljivosti metode. Nadalje, stablo odlučivanja omogućuje rad s nedostajućim vrijednostima koje se promatraju kao dodatna kategorija vrijednosti značajke.

5.5.2 Nedostaci

Nestabilnost, odnosno mala promjena ulaznih podataka pomoću kojih se trenira model može rezultirati velikim promjenama u topologiji stabla. Mala promjena podataka može dovesti do sasvim druge podjele koja dalje utječe na sve grane ispod sebe. Također, stabla odlučivanja imaju prisilnu interakciju između varijabli, što ih čini neučinkovitijima ako većina varijabli nema ili ima vrlo slabe interakcije.

5.6 Random Forest modeliranje

Kao klasifikacijski algoritam, Random Forest djeluje tako da gradi mnoštvo stabala u vrijeme treniranja te proizvodi klasifikaciju ili srednja predviđanja pojedinih stabala. Za razliku od stabla odlučivanja kod kojeg postoji problem pretreniranosti, model Random Forest smanjuje mogućnost da prediktivni model bude pretreniran jer u izvedbu se stavljaju nekoliko različitih modela [11]. Direktno očituje se između broja stabala i dobivenih rezultata, što je veći broj stabala, rezultat analize je točniji. Glavna razlika u odnosu na stablo odlučivanja leži u pronalaženju izvornog čvora i podjele čvorova značajki jer se oni izvode nasumično.

5.6.1 Prednosti

Prednosti Random Forest modela očituju se u korištenju istog algoritma i za klasifikaciju i regresiju. Nadalje on može obraditi nedostajuće vrijednosti te u trenucima kada imamo više stabala on neće prepuniti model te može modelirati klasifikator za kategorijske vrijednosti.¹¹ Efikasan je na velikim skupovima podataka i za veliki broj atributa.

5.6.2 Nedostaci

Vremenska i prostorna složenost nedostaci su Random Forest prediktivnog modela.

Kako bi uvidjeli koliko zapravo možemo kontaktirati klijente s obzirom na model logističke regresije, u nastavku je predstavljen grafički prikaz koji će nam to i ukazati.

Konfuzijska matrica primijenjena na RF model ukazuje sljedeće:

Stvarno/Predikcija	NE	DA	UKUPNO
NE	2877	220	3097
DA	544	577	1121
UKUPNO	3421	797	4218

Grafički prikaz 9. Prediktivni model Random Forest

¹¹ <https://dataaspirant.com/2017/05/22/random-forest-algorithm-machine-learning/>

-
- Za 2877 ljudi koji nisu otišli model je predvidio da se odljev neće dogoditi
 - Za 220 ljudi koji nisu otišli model je predvidio da će otići
 - Za 544 koji jesu otišli, model je predvidio kako neće otići
 - Za 577 ljudi koje je otišlo, model je predvidio da će otići

Također, kao i za stablo odlučivanja potrebno je odrediti točnost modela te ona za konfuzijsku matricu RF modela iznosi 81,8%.

5.7 Obuhvatnost i preciznost modela

U vidu evaluacije i testiranja rezultata modela za stablo odlučivanja, random forest i logističke regresije u nastavku su predstavljene preciznost i obuhvatnost, dvije izuzetno važne metrike vrednovanja modela. Dok se preciznost odnosi na postotak rezultata koji su relevantni, obuhvatnost ukazuje na one koje su ispravno klasificirane našim algoritmom. Oni su obrnuto proporcionalni jedni drugima te je razumijevanje njih važno za izgradnju učinkovitog sustava klasifikacije.

Preciznost se još naziva i pozitivna prediktivna vrijednost koja se matematički izražava formulom:

$P = TP / (TP + FP)$; prema kojoj je TP broj Istinitih pozitivnih vrijednosti / ukupni broj istinitih pozitivnih vrijednosti

U predstavljenom setu podataka ona ukazuje na postotak korisnika koje je stvarno otišlo od operatera ukoliko je model predvidio odlazak. Nasuprot tome, obuhvatnost modela ili osjetljivost modela predstavlja predstavljena je matematičkom formulom :

$R = TP / (TP + FN)$; prema kojoj je TP broj Istinitih pozitivnih vrijednosti / ukupan broj korisnika

Obuhvatnost skupa podrazumijeva postotak stvarnih korisnika koje je model obuhvatio, odnosno predvidio da će otići. U nastavku je predložen tablični prikaz vrijednosti obuhvatnosti i preciznosti modela prema prediktivnim modelima stablo odlučivanja, logistička regresija te Random Forest modeliranje.

Prediktivni modeli	Preciznost	Obuhvatnost
Stablo odlučivanja	65,60%	40,14%
Logistička regresija	72,09%	50,93%
Random Forest	72,3%	51,47%

Grafički prikaz 10.Obuhvatnost i Preciznost modela

Logistička regresija

Preciznost modela:

Za one koje je model predvidio da će otići, postavlja se pitanje koliko ih je stvarno otišlo, stoga on po modelu iznosi 72,09 % , odnosno to je postotak koliko ih je stvarno otišlo, ukoliko je model rekao da će otići.

Obuhvatnost modela:

Za one koji su stvarno otišli, koliki postotak stvarnih churnera je model obuhvatio odnosno predvidio da će otići. 1121 korisnika koji su stvarno otišli, model je prepoznao njih 571, odnosno ukupno će otići 50,93% klijenata. U vidu dobivanja pouzdanog modela, ponovno je primijenjen lift model koji će nam ukazati jeli stablo odlučivanja bio pouzdan ili nepouzdan model.

Stablo odlučivanja

Preciznost modela:

Za one koje je model predvidio da će otići, postavlja se pitanje koliko ih je stvarno otišlo, stoga on po modelu iznosi 65,60 % , odnosno to je postotak koliko ih je stvarno otišlo, ukoliko je model rekao da će otići.

Obuhvatnost modela:

Za one koji su stvarno otišli, koliki postotak stvarnih odlaska koje je model obuhvatio odnosno predvidio da će otići. 1121 korisnika koji su stvarno otišli, model je prepoznao njih 450, odnosno ukupno će otići 40,14% klijenata.

Random Forest

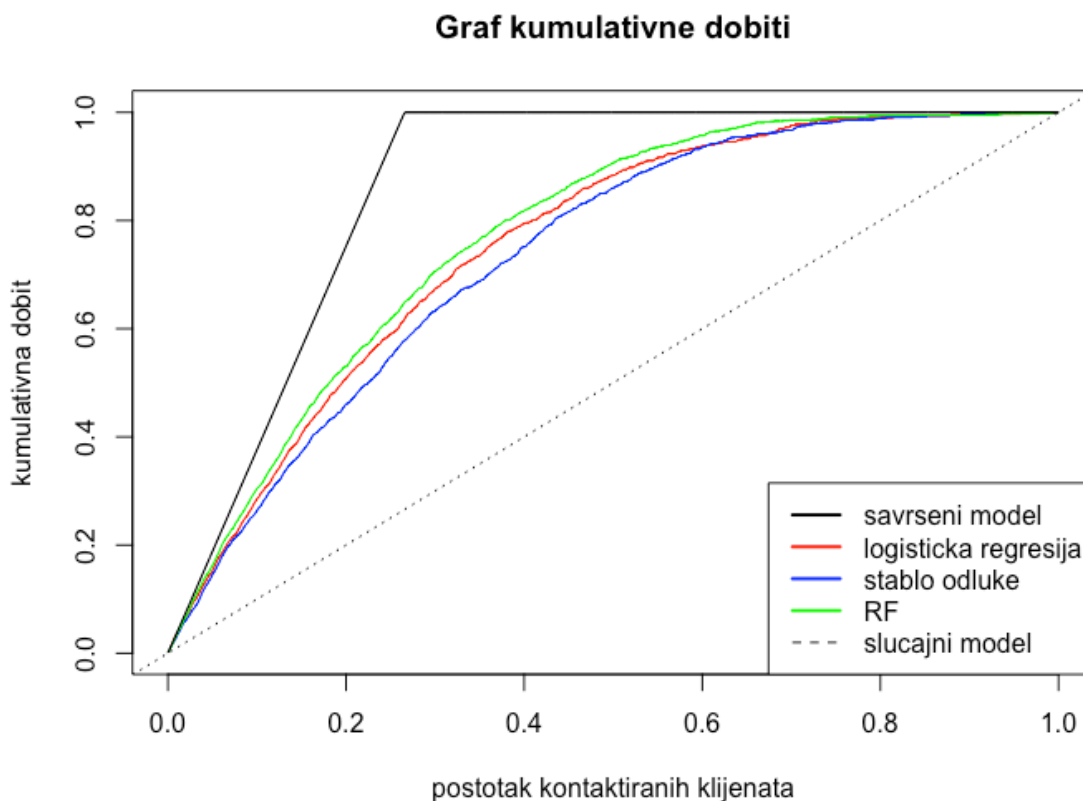
Preciznost modela:

Za one koje je model predvidio da će otići, postavlja se pitanje koliko ih je stvarno otišlo, stoga on po modelu iznosi 72,3 % , odnosno to je postotak koliko ih je stvarno otišlo, ukoliko je model rekao da će otići.

Obuhvatnost modela:

Za one koji su stvarno otišli, koliki postotak stvarnih churnera je model obuhvatio odnosno predvidio da će otići. 1121 korisnika koji su stvarno otišli, model je prepoznao njih 577, odnosno ukupno će otići 51,47% klijenata.

5.8 Kumulativna dobit



Grafički prikaz 11. Graf kumulativne dobiti

Graf predstavlja kako postotak ukupnog broja kontaktiranih churnera ovisi o postotku kontaktiranih klijenata. Ukoliko su kontaktirani klijenti s najvećom vjerojatnosti churra iz testnog skupa, model predviđa sljedeće:

Slučajni model predstavlja nasumično odabrane korisnike iz testnog skupa

- Za 20% kontaktiranih korisnika model je obuhvatio 20% churnera
- Za 80% kontaktiranih korisnika model je obuhvatio 80% churnera

RF model predstavlja:

- Za 20% kontaktiranih korisnika model je obuhvatio 53% churnera

Za Stablo odlučivanja:

-
- Za 20% kontaktiranih korisnika model je obuhvatio 46% churnera

Logistička regresija ukazuje:

- Za 20% kontaktiranih korisnika model je obuhvatio 50% churnera

Savršeni model predstavlja onaj model u kojem je vjerojatnost churna svakog pravog churnera veća od vjerojatnosti ne churnera. Tako model predviđa da ćemo sa 20% kontaktiranih klijenata obuhvatiti 95% churnera.

Za kraj potrebno je predstaviti lift krivulju koja ukazuje na djelotvornost prediktivnog modela izračunatog kao omjer rezultata dobivenog s prediktivnim modelim i bez njega. Ona ukazuje na preformansu modela te što je veće područje između krivulje dizanja i osnovne linije, model je bolji. Tako za stablo odlučivanja lift krivulja ukazuje na 2.30, logistička regresija 2.53, za RF ona iznosi 2.64, što ukazuje da je RF ima najbolju preformansu modela.

6. Zaključak istraživanja

Prediktivna analiza ima za cilj omogućiti organizacijama identifikaciju obrazaca, prilike i probleme na temelju podataka koje posjeduju. U životnom ciklusu upravljanja klijentima, korisnički odljev odnosi se na odluku klijenta prema kojoj on završava poslovni ugovorni odnos koji je imao do definiranog trenutka. S obzirom da lojalnost i odljev klijenata zajedno čini 100%, ukoliko tvrtka ima 60% stopu lojalnosti, njihov gubitak ili odljev korisnika je 40%, predikcija je neophodna kako bi se uvidjelo koliki je postotak odljeva korisnika te pronaći načine kako ga spriječiti. U vidu predstavljenog, korišteni su prediktivni modeli koji će ukazati na postotak odlaska klijenata koji se može spriječiti ukoliko ih se minimalno kontaktira a zatim marketinškim aktivnostima i promocijama zadrži. Postavljeni ciljevi uključivali su saznanja o klijentima koji će otkazati pretplatu, te na temelju analize potvrđeno je kako klijenti koji imaju mjesečni ugovor s naplatom bez papira unutar godine dana imaju najveći postotak odljeva dok s druge strane, klijenti koji imaju ugovor 1-2 godine, s ne više od 12 mjeseci **tenure** i ne koriste plaćanje bez papira imaju najmanju mogućnost odljeva. Nadalje, ne postoji povezanost između spola i odljeva korisnika. Također, karakteristike poput **tenure grupe**, ugovor, plaćanje bez papira, mjesečna naplata te usluge interneta pokazale su se da imaju veliku ulogu kod odljeva klijenata. Ukoliko sagledamo prediktivne modele, njihovu preformansu nad skupom podataka od 14,064 redaka podataka, u 22 kolumne prema kategorijama te napravljene unaprijed podjele podataka za testiranje (70%) i treniranje (30%) dolazimo do sljedećeg: prediktivni modeli Stablo odlučivanja, Random Forest i logistička regresija pokazali su veliku uporabu u predikciji odlaska klijenata s obzirom na njihovu točnost. Svaki od modela ima visok postotak točnosti s time da Random Forest ima najveću, čak 81,88% točnosti. Nadalje, grafikon kumulativne dobiti, koji predstavlja postotak ukupnog broja kontaktiranih churnera ovisi o postotku kontaktiranih klijenata. Ukoliko su kontaktirani klijenti s najvećom vjerojatnosti churina iz testnog skupa, Random Forest model je prevideo kako za 20% kontaktiranih korisnika, model će obuhvatiti 53% churnera, dok prediktivni modeli stablo odlučivanja, logistička regresija i slučajni model obuhvaćaju najmanji postotak churnera u skupu. Sukladno saznanjima o prediktivnom modelu Random Forest, on se pokazao kao najbolji model za predikciju churina u setu podataka.

Literatura

- [1] <https://futurumresearch.com/>
- [2] <https://www.forbes.com/sites/gilpress/2017/11/09/10-predictions-for-the-internet-of-things-iot-in-2018/#1e6aa84335e7>
- [3] <https://www.idc.com/getdoc.jsp?containerId=prUS43188017>
- [4] <https://www.gartner.com/en/newsroom/press-releases/2017-04-24-gartner-survey-shows-42-percent-of-ceos-have-begun-digital-business-transformation>
- [5] <https://www.statista.com/statistics/816735/customer-churn-rate-by-industry-us/>
- [6] <https://www.idc.com/getdoc.jsp?containerId=prUS43381817>
- [7] SPREMIĆ; Digitalna transformacija poslovanja, Sveučilište u Zagrebu, 2017.
- [8] <https://www.apple.com/newsroom/2018/01/apple-announces-effortless-solution-bringing-health-records-to-iPhone/>
- [9] <https://dataaspirant.com/2017/05/22/random-forest-algorithm-machine-learning/>
- [10] <https://neilpatel.com/blog/how-netflix-uses-analytics/>
- [11] <https://dataaspirant.com/2017/05/22/random-forest-algorithm-machine-learning/>
- [12] <https://deepsense.ai/ai-trends-2019/>
- [13] <https://becominghuman.ai/4-ai-trends-that-will-transform-the-telecom-industry-in-2019-1bf0d58637cd>
- [14] <https://technology.ihs.com/598720>
- [15] Mršić L., Klepac G., Kopal R. (2015) Developing Churn Models Using Data Mining Techniques and Social Network Analysis, IGI Global, DOI: 10.4018/978-1-4666-6288-9

Ilustracije

Grafički prikaz 1. Korelacijski prikaz numeričkih varijabli.....	30
Grafički prikaz 2. Grafički prikaz kategoričkih varijabli	31
Grafički prikaz 3. Grafički prikaz kategoričkih varijabli	32
Grafički prikaz 4. Grafički prikaz kategoričkih varijabli	33
Grafički prikaz 5. Grafički prikaz kategoričkih varijabli	34
Grafički prikaz 6. Prediktivni model Logistička regresija	35
Grafički prikaz 7. Stablo odlučivanja	37
Grafički prikaz 8. Prediktivni model	38
Grafički prikaz 9. Prediktivni model Random Forest.....	39
Grafički prikaz 10. Obuhvatnost i Preciznost modela.....	41
Grafički prikaz 11. Graf kumulativne dobiti	44

„Pod punom odgovornošću pismeno potvrđujem da je ovo moj autorski rad čiji niti jedan dio nije nastao kopiranjem ili plagiranjem tuđeg sadržaja. Prilikom izrade rada koristio sam tuđe materijale navedene u popisu literature ali nisam kopirao niti jedan njihov dio, osim citata za koje sam naveo autora i izvor te ih jasno označio znakovima navodnika. U slučaju da se u bilo kojem trenutku dokaže suprotno, spreman sam snositi sve posljedice uključivo i poništenje javne isprave stečene dijelom i na temelju ovoga rada“.

U Zagrebu, 25.03.2019.

Dražen Tomić