

UNIVERZA V LJUBLJANI
FAKULTETA ZA RAČUNALNIŠTVO IN INFORMATIKO

Vid Babič

**Analiza in napovedovanje števila
prikazov spletnih kampanj**

DIPLOMSKO DELO

VISOKOŠOLSKI STROKOVNI ŠTUDIJSKI PROGRAM
PRVE STOPNJE
RAČUNALNIŠTVO IN INFORMATIKA

MENTOR: doc. dr. Tomaž Curk

SOMENTOR: dr. Jure Bordon

Ljubljana, 2018

COPYRIGHT. Rezultati diplomske naloge so intelektualna lastnina avtorja in Fakultete za računalništvo in informatiko Univerze v Ljubljani. Za objavo in koriščenje rezultatov diplomske naloge je potrebno pisno privoljenje avtorja, Fakultete za računalništvo in informatiko ter mentorja.

Besedilo je oblikovano z urejevalnikom besedil L^AT_EX.

Fakulteta za računalništvo in informatiko izdaja naslednjo nalogo:

Tematika naloge:

Spletno oglaševanje je podvrženo zakonitostim trga, panoge in tudi odločitvam posameznih podjetij. Na podlagi analize podatkov o spletnem oglaševanju poskusite odkriti različne načine in dinamike oglaševanja. Z uporabo metod strojnega učenja zgradite in ovrednotite model za napovedovanje števila prikazov posameznih oglasov.

Na tem mestu bi se rad zahvalil mentorju doc. dr. Tomažu Curku za odlično vodenje, odzivnost, strokovno pomoč in nasvete pri izdelavi diplomske naloge.

Enaka zahvala gre somentorju dr. Juretu Bordonu in ostalim članom ekipe Data Insights podjetja Celtra d.o.o., ki so mi omogočili razširitev dela v mojo diplomsko nalogo in mi pri tem nudili vso potrebno pomoč ter prijetno, pozitivno in stimulatивно delovno okolje.

Hvala prijateljem in sošolcem za dobro družbo, motivacijo in še dodatno popestritev študija.

Posebna zahvala pa gre mojemu dekletu in družini, hvala za neizmerno podporo, vzpodbudo in pomoč, ki ste mi jo nudili na poti do cilja.

Kazalo

Povzetek

Abstract

1	Uvod	1
1.1	Kratka zgodovina oglaševanja	1
1.2	Pregled področja in glavni cilji	2
1.3	Vsebina diplomske naloge	5
2	Podatki o prikazovanju oglasov	7
2.1	Vrste podatkov	7
2.2	Pridobivanje podatkov	7
3	Osnovne lastnosti podatkov o kampanjah	13
3.1	Porazdelitev števila prikazov kampanj	13
3.2	Sprememba sestave kampanj skozi čas	16
3.3	Porazdelitev časa izvajanja kampanj	21
4	Napovedovanje števila prikazov kampanj	35
4.1	Podatki	35
4.2	Metode	36
4.3	Rezultati	37
5	Zaključek	39

Povzetek

Naslov: Analiza in napovedovanje števila prikazov spletnih kampanj

Avtor: Vid Babič

Povzetek: Cilj diplomskega dela je bil pridobiti novo znanje o načinih oglaševanja in lastnostih spletnih kampanj ter napovedovanje števila prikazov kampanje po določenem obdobju trajanja le-te. V prvem delu diplomskega dela smo iz različnih virov zgradili podatkovno množico in podatke analizirali glede na različne lastnosti kampanj (število prikazov, leto aktivnosti, čas trajanja). Ugotovili smo, da obstajajo različni vzorci, predvsem pri analizi po času trajanja. V drugem delu smo preizkusili uspešnost napovedovanja števila prikazov kampanje. Uporabili smo tri različne podatkovne množice, ki so se razlikovale po času, ko začnemo zbirati podatke za napovedovanje. Za napovedovanje smo uporabili pet različnih metod (linearna regresija, regresijsko drevo, naključni gozdovi, metoda podpornih vektorjev, k najbližjih sosedov). Metode smo ocenili s petkratnim prečnim preverjanjem in z različnimi merami uspešnosti.

Ključne besede: analiza, spletna kampanja, spletno oglaševanje, napovedovanje.

Abstract

Title: Analysis and prediction of online campaign impressions

Author: Vid Babič

Abstract: The purpose of the diploma work was to gain new knowledge about the methods of advertising, the characteristics of online campaigns and to predict the number of campaign impressions after a certain period of duration. In the first part of the thesis, we built a data set from different sources and analyzed the data according to different campaign characteristics (number of impressions, year of activity, duration). We discovered different patterns, especially in terms of campaign duration. In the second part, we tested the performance of predicting the number of campaign impressions. We used three data sets that differed by the time we started to collect forecasting data. We used 5-fold cross-validation to evaluate five regression methods (linear regression, regression tree, random forests, support vector machine, k nearest neighbors) for the task.

Keywords: analysis, online campaign, online marketing, prediction.

Poglavje 1

Uvod


Oglaševanje je najpomembnejša tržno-komunikacijska dejavnost. Je vsaka plačana oblika tržnega komuniciranja, s katero želimo uporabnike obvestiti o izdelkih ali storitvah. Oglaševanje ima lahko več namenov: uporabnike obveščamo o novih izdelkih, želimo povečati prepoznavnost podjetja ali dvigniti prodajo izdelkov. Poznamo različne oblike oglaševanja: oglaševanje objekta, oglaševanje subjekta, osebno oglaševanje in množično oglaševanje [6].

1.1 Kratka zgodovina oglaševanja

Način oglaševanja se je skozi zgodovino neprestano spreminjal, vse od oglaševanja od “ust do ust” do oglaševanja v časopisih, na reklamnih panojih, preko radija, televizije in v novih medijih [12]. Z večjo dostopnostjo in veliko preživetega časa na spletu se je v zadnjih letih na vrh oglaševalnih načinov povzpelo spletno oglaševanje.

To dejstvo ne preseneča, saj je v letu 2018 število uporabnikov interneta preseglo 4 milijarde. Po podatkih iz januarja 2018, povprečen uporabnik približno 6 ur dnevno uporablja internetne storitve ali naprave povezane na internet [3]. Izredno veliko število uporabnikov in dejstvo, da uporaba interneta raste, naredi spletno oglaševanje izjemno učinkovito. Poleg tega spletno oglaševanje ponuja tudi določene možnosti, kot so, na primer, slede-

nje (*tracking*) in učinkovitejše ciljanje specifične publike. Vse to za veliko nižjo ceno kot pri tradicionalnih načinih oglaševanja, kar je razvidno tudi iz slike 1.1.



Slika 1.1: Primerjava cen različnih načinov oglaševanja [7].

Med vrste spletnega oglaševanja spadajo: oglaševanje preko elektronske pošte, slikovne pasice (*banner*), oglas vmesne strani, oglas v pojavnem oknu (*popup ad*), oglasi HTML [13], itd.

1.2 Pregled področja in glavni cilji

Z večanjem popularnosti spletnega oglaševanja se večja tudi nabor podatkov, ki jih lahko zbiramo in analiziramo. Število spletnih kampanj se iz dneva v dan povečuje in število prikazov enega samega oglasa lahko sega tudi preko milijarde. Kampanjo lahko definiramo kot organizirano, široko zasnovano dejavnost z določenim ciljem [9]. Spletna kampanja je tako vrsta oglaševalske

kampanje, sestavljena iz enega ali več spletnih oglasov. Njen namen je, da preko prikazovanja spletnih oglasov dosežemo želeni cilj, naj bo to večja prepoznavnost podjetja, dvig prodaje izdelka ali kaj drugega [9].

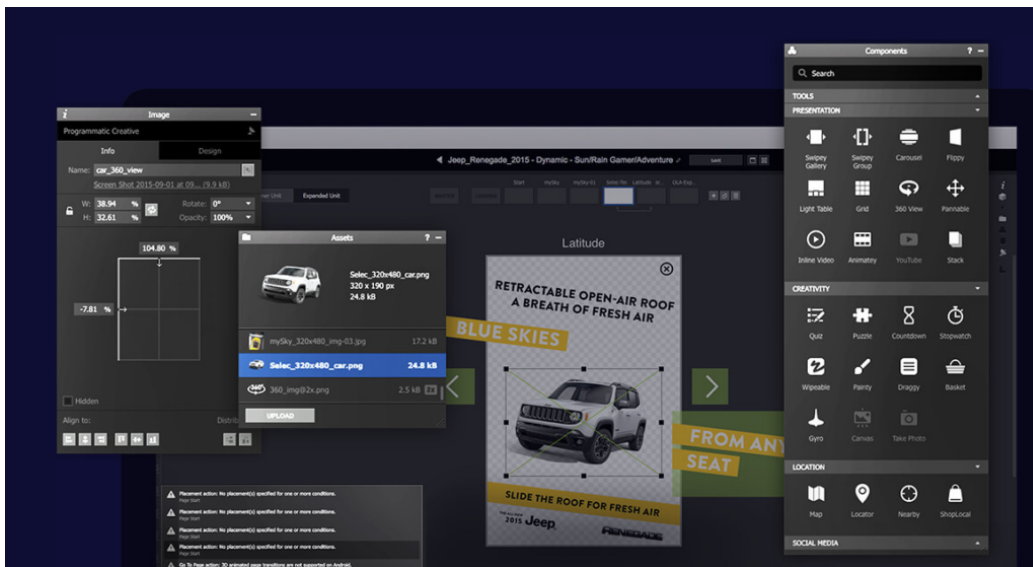
Vsako podjetje pred začetkom oglaševalske kampanje določi višino sredstev, ki bodo namenjena oglaševanju. Le-ta so poleg drugih faktorjev v glavnem odvisna od števila in lokacije prikaza oglasov. Podjetja pa lahko oglašujejo na zelo različne načine. Spletna kampanja ima lahko malo ali veliko prikazov oglasov, lahko traja daljše obdobje ali pa samo nekaj dni. Analiza podatkov kampanj več različnih podjetij nam lahko poda veliko novega znanja o tem, kako podjetja pristopijo k spletnemu oglaševanju. Prav tako lahko iz podatkov poskušamo ugotoviti, ali obstajajo različne oblike oglaševanja spletne kampanje glede na dnevno število prikazov oglasov. V diplomski nalogi zasledujemo dva pomembna cilja:

1. Pridobiti osnovne zakonitosti o podatkih spletnih kampanj.
2. Iz oblike krivulje števila prikazov kampanje po nekaj dnevih preveriti, ali je mogoče napovedati število prikazov kampanje v prihajajočem dnevu.

Podatke o spletnih kampanjah, času aktivnosti kampanje in številu prikazov oglasov kampanje po dnevih smo za potrebe analize dobili pri podjetju Celtra d.o.o [1].

Celtra d.o.o. se na trgu mobilnega oglaševanja uveljavlja s svojo platformo *Creative Management Platform* (CPM) 1.2. Gre za platformo *SaaS* (*software-as-a-service*), ki omogoča oblikovanje in distribucijo tako imenovanih oglasov "*rich-media*" za mobilne naprave ali spletne strani prilagojene mobilnim odjemalcem [8]. Skozi čas se je preko platforme ustvarilo in distribuiralo že več deset tisoč spletnih kampanj veliko različnih podjetij, zato so bili podatki, pridobljeni pri podjetju Celtra d.o.o, odlični za opravljanje analize.

Z bolj specifičnimi analizami in napovedovanjem so se v preteklosti že ukvarjali. Leta 2009 je David S. Evans v reviji "*Journal of Economic Perspec-*



Slika 1.2: Platforma *Creative Management Platform* (CPM) [2].

tives” [4] predstavil analizo spletnega oglaševanja v ZDA. Opisal je področje in zgodovino le-tega, naredil različne primerjave, predvsem z oglaševanjem v časopisih, in predstavil finančni aspekt takega načina oglaševanja. Prav tako sta Anindya Ghose in Sha Yang leta 2009 izdala članek z naslovom “*An Empirical Analysis of Search Engine Advertising: Sponsored Search in Electronic Markets*” [5], v katerem opisujeta potek in rezultate svoje analize oglasov, prikazanih v spletnih iskalnikih. Analizirali sta besedno sestavo oglasov, različne načine postavitve oglasa in kvaliteto strani, na kateri se je oglas pokazal. Vse to sta nato primerjala z uspešnostjo oglasa in ceno prikaza. Pri podjetju Yahoo Inc. so se lotili napovedovanja števila prikazov oglasa in možnosti, da bo uporabnik strani na oglas kliknil [10]. Osredotočali so se predvsem na majhne oglase, ki se prikazujejo glede na vsebino strani, tako imenovan “*Contextual advertising.*” Leta 2010 so se ukvarjali z napovedovanjem uspešnosti spletnega oglasa glede na različne poslovne metrike in statistiko podatkov iz preteklosti [11].

V diplomski nalogi smo želeli analizirati bolj širok nabor podatkov in tako dobiti pregled nad celotnim področjem spletnega oglaševanja. V primerjavi

z drugimi raziskavami smo se v tej diplomski nalogi odločili za analizo celotnih kampanj in ne posameznih oglasov, s poudarkom na iskanju razlik med različnimi tipi podjetij. Prav tako smo se osredotočili za analizo kampanj večjega števila podjetij iz različnih panog in s tem dobiti rezultate, ki niso vezani na specifično podjetje ali področje. Kampanje, ki smo jih analizirali, so tako sestavljene iz različnega števila in vrst oglasov. Lastniki kampanj, torej podjetja, pa so lahko manjša ali večja in iz različnih držav oziroma kontinentov ter se ukvarjajo z različnimi panogami.

1.3 Vsebina diplomske naloge

Diplomska naloga je sestavljena iz dveh delov. V prvem, večjem delu naloge smo pripravili podatke in jih analizirali glede na trajanje kampanje, skupnega števila prikazov oglasov, vrsto stranke in čas aktivnosti kampanje. V drugem delu smo se osredotočili na napovedovanje števila prikazov kampanje za specifičen dan. Izbrali smo različne začetne točke, ki so služile kot prvi dan kampanje, nato pa po nekaj dneh zbiranja podatkov o številu prikazov kampanje poizkusili napovedati število prikazov za prihajajoči dan.

Poglavje 2

Podatki o prikazovanju oglasov

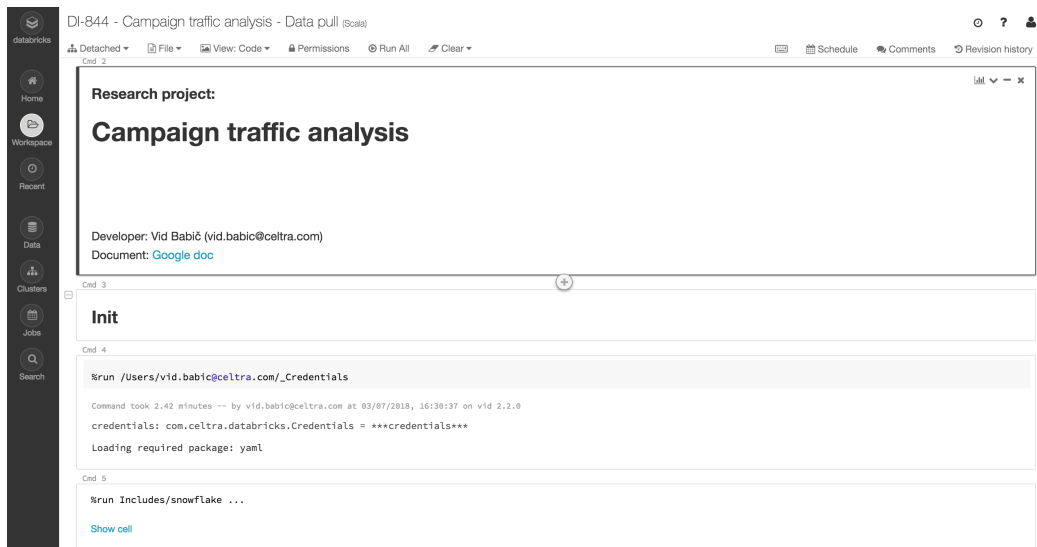
2.1 Vrste podatkov

Za potrebe analize smo se odločili za uporabo podatkov o skupnem številu prikazov oglasov kampanj, oziroma preprosto prikazov kampanj. Na voljo smo imeli podatke razdeljene po različnih časovnih enotah, vrstah strank, vrstah oglasov, lokacijah oglaševanja in podobno. Odločili smo se za uporabo podatkov o posameznih kampanjah natančnosti enega dneva, z dodatnimi informacijami o vrsti stranke in njeni šifri.

2.2 Pridobivanje podatkov

Za pridobivanje podatkov in oblikovanje končne podatkovne množice smo uporabili orodje *Databricks*. Orodje je namenjeno obdelavi velikih količin podatkov (*Big Data*) in deluje na osnovi tehnologije *Apache Spark*. Ponuja spletno platformo, na kateri lahko programiramo v več podprtih programskih jezikih, na način podoben kot pri orodju *IPython/Jupyter notebook*, prikazanem na sliki 2.1. Za potrebe pridobivanja podatkov smo se odločili za uporabo jezikov *SQL* in *Scala*.

Podatki, ki smo jih potrebovali za pridobitev končne množice, so bili shranjeni v podatkovno bazo *Snowflake*. Do podatkovne baze je bilo mogoče



Slika 2.1: Delovno okolje *Databricks*.

dostopati na dva načina. Lahko smo se povezali direktno na bazo preko *Snowflake* programskega vmesnika za *Databricks* (*Snowflake API*). Lahko pa smo do podatkov dostopali tudi preko analitičnega programskega vmesnika podjetja Celtra d.o.o (*Analytics API*).

Pred začetkom pridobivanja podatkov se je bilo potrebno najprej povezati na API podjetja Celtra d.o.o in API podatkovne baze *Snowflake* ter poskrbeti za pravilna uporabniška imena in gesla. Programski jezik *SQL* smo uporabljali za poizvedbe in ostale manipulacije s podatki, *Scala* pa predvsem za shranjevanje začasnih tabel, povezovanje na programske vmesnike, hitre preproste vizualizacije in izvoz končne podatkovne množice.

Na začetku smo zbrali več zbirk podatkov o kampanjah. Prva množica je vsebovala ID kampanje in ID stranke, ki si kampanjo lasti, ter število prikazov kampanje za vsak dan, ko je bilo število le-teh večje od nič.

Podatkovna množica

Atributi:

Date

Campaign ID

Account ID

Impressions (Day)

Opis atributov:

Date - datum

Campaign ID - enolični identifikator kampanje

Account ID - enolični identifikator stranke

Impressions (Day) - število prikazov kampanje
za specifičen dan

Ker smo pridobili podatke le o dnevih, v katerih je kampanja imela vsaj en prikaz, želeli smo pa tudi dneve, ko prikazov ni bilo, smo potrebovali tudi zbirko datumov. Vedeli smo, da se nobena kampanja ni začela pred 1. 1. 2014, zato smo izbrali seznam datumov od 1. 1. 2014 do 29. 6. 2018.

Podatkovna množica

Atributi:

Date range

Opis atributov:

Date range - dan med 1.1.2014 in 29.6.2018

Pridobili smo podatke o skupni vsoti prikazov za vsako kampanjo od dneva, ko je bila kampanja ustvarjena.

Podatkovna množica

Atributi:

Campaign ID

Account ID

Impressions (Total)

Opis atributov:

Impressions (Total) - skupna vsota prikazov kampanje

Na tej točki smo implementirali možnost, da uporabnik za potrebe testiranja izbere le množico podatkov o izbranem številu naključnih kampanj ali kampanjah, ki so skozi čas zbrale največ prikazov. Sledil je tako imenovan "cross join" tabele izbranih enoličnih identifikatorjev kampanj z zbirko dni.

Podatkovna množica

Atributi:

Campaign ID

Date range

Pridobljeno tabelo smo nato združili s tabelo o številu prikazov za vsako kampanjo po dnevih. Tako smo dobili tabelo, kjer ima vsaka kampanja podatek tudi za dan, v katerem ni imela nobenega prikaza.

Podatkovna množica

Atributi:

Campaign ID

Date range

Impressions (Day)

Zgornja tabela je vsebovala podatke o kampanjah za vse dni med 1. 1. 2014 in 29. 6. 2018. Torej je imela kampanja, ki je bila ustvarjena kadarkoli po začetnem datumu, podatke o dnevih, preden je bilo pozitivno število prikazov sploh mogoče. Prav tako so imele zaključene kampanje podatke o dnevih po svojem 'aključku. Da bi se znebili obeh odvečnih delov podatkovne množice, smo se odločili, da v množici odstranimo podatke o kampanjah pred njihovim nastankom in po dnevu, ko je kampanja imela zadnji prikaz. Podatek o zadnjem dnevu smo že imeli, potrebovali smo še podatek o dnevih, ko so bile kampanje ustvarjene. Pridobili smo sledečo tabelo:

Podatkovna množica

Atributi:

Campaign ID

Campaign creation timestamp

Opis atributov:

Campaign creation timestamp - dan, ko je bila
kampanja ustvarjena

Tako smo imeli vse potrebne podatke za omejitev množice. Za lažje delo s podatki smo vsaki vrstici dodali še število dni od začetka kampanje, kateri pripada. Kampanjam smo dodali tudi podatek o tipu lastnika in več dodatnih stolpcev z različnimi podatki o deležu prikazov, vsoti prikazov, oznakami v vrsticah, kjer so izpolnjenimi določeni pogoji in podobno. S tem smo dobili končno množico.

Podatkovna množica

Atributi:

Campaign ID
Account ID
Client type
Date
Impressions
Share (Impressions)
Cumulative (Impressions)
Share (Cumulative impressions)
Row number (Campaign creation date)
Row number (Campaign first impression)
Row number (Campaign first 10.000th impression date)
Row number (Campaign day with the most impressions)

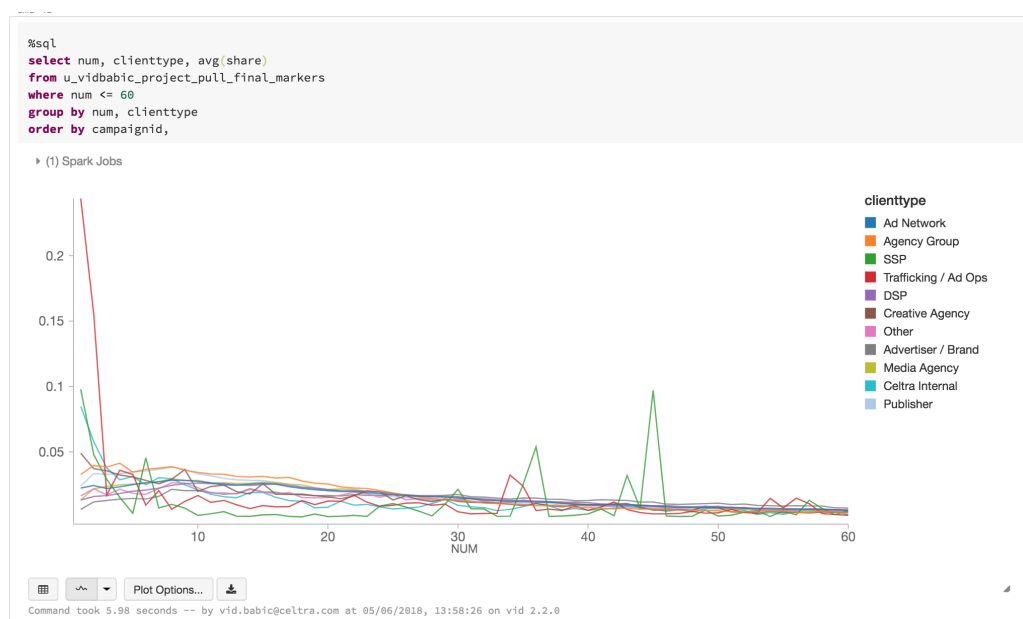
Opis atributov:

Client type - tip stranke
Share (Impressions) - delež prikazov od vseh prikazov kampanje
Cumulative (Impressions) - vsota prikazov do izbranega dne
Share (Cumulative impressions) - delež vsote prikazov od vseh prikazov kampanje
Row number (Creation) - zaporedni dan od dneva, ko je bila kampanja ustvarjena
Row number (First impression) - zaporedni dan od dneva, ko je kampanja imela prvi prikaz
Row number (10.000th impression) - zaporedni dan od dneva, ko je kampanja dosegla skupno 10.000 ali več prikazov
Row number (Max impressions) - zaporedni dan od dneva z največ prikazi

Lastnosti podatkovne množice:

- Število vrstic: 15.971.043
- Število stolpcev: 12
- Število strank: 953
- Število kampanj: 75.792
- Število prikazov: 258.765.002.098

Orodje *Databricks* ponuja možnost osnovnih vizualizacij podatkov. Različne dele podatkov smo vizualizirali z različnimi grafi (primer: slika 2.2), a hitro



Slika 2.2: Vizualizacija podatkov v okolju *Databricks*.

ugotovili, da orodje ne ponuja dovolj možnosti, oziroma ni dovolj zmogljivo za naš namen uporabe.

Poglavje 3

Osnovne lastnosti podatkov o kampanjah

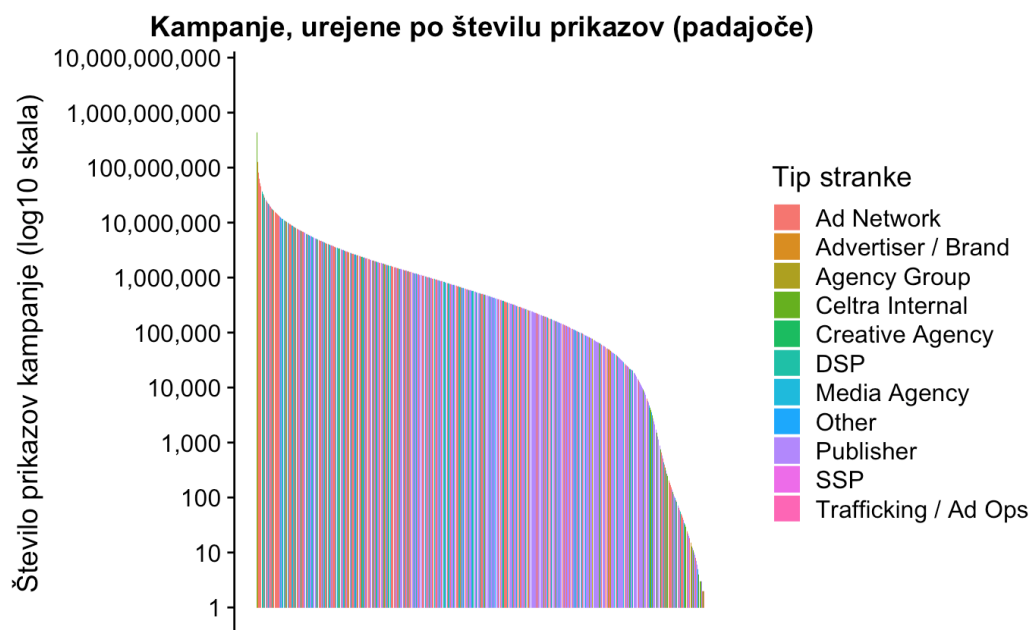
Pri izbiranju razvojnega okolja smo se odločali med programskima jezika *R* in *Python*. Ob pregledu funkcionalnosti smo se odločili za uporabo jezika *R* in orodja *RStudio*. Eden od razlogov je bila tudi knjižnica “*ggplot2*,” ki omogoča dobro vizualizacijo podatkov. Analizo smo se odločili ločiti na različne dele glede na lastnosti podatkov, ki smo jih analizirali. V velikem delu smo se osredotočali na razlike med kampanjami različnih tipov strank. Analize smo razdelili na sledeče sklope:

- število prikazov kampanje,
- leto začetka kampanje,
- dolžino kampanje.

3.1 Porazdelitev števila prikazov kampanj

Na začetku analize kampanj smo se osredotočili na skupno število prikazov kampanje (ang. *impressions*). Za začetek smo si želeli ogledati, kako so kampanje razporejene po številu prikazov. Sešteli smo prikaze vsake kampanje po dnevih in dobili skupno število prikazov za vsako kampanjo. Zaradi velike razlike med manjšimi in večjimi kampanjami smo za prikaz uporabili loga-

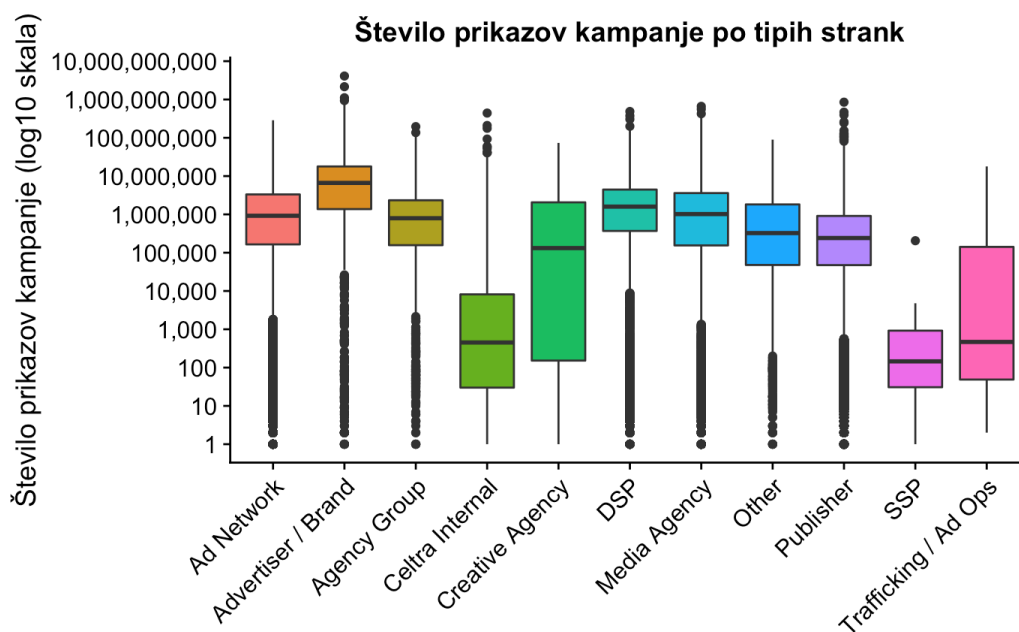
ritemsko skalo z osnovo 10. Slika 3.1 pokaže, da večina kampanj, urejenih po številu prikazov, leži med približno 10.000.000 in 10.000. Kampanje so obarvane glede na tip stranke, kateri pripadajo.



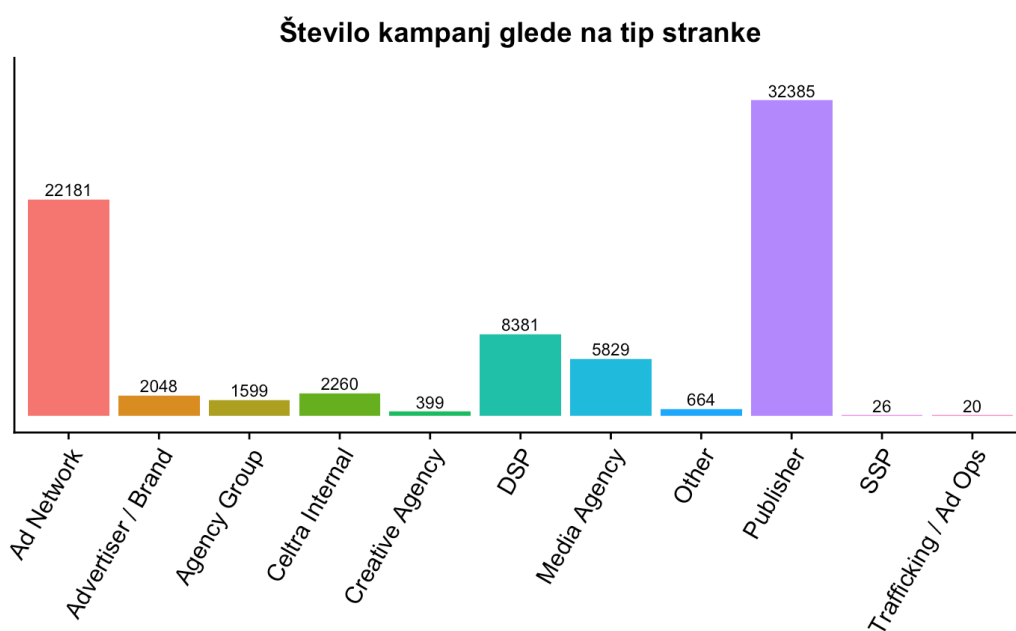
Slika 3.1: Kampanje, urejene po številu prikazov.

Barva na sliki 3.1 ne poda zadostne informacije o porazdelitvi tipa strank glede na število prikazov kampanj. Kampanje smo zato razdelili po tipu stranke ter vsak tip prikazali s škatlo z brki. Uporabili smo enako množico, kot pri prvem grafu (slika 3.1).

Slika 3.2 prikaže vidno razliko med različnimi tipi strank. Največja števila dosegajo kampanje, katerih lastniki so stranke tipa “*Advertiser / Brand*”, med katere med drugim spada večina kampanj z največ prikazi. Najmanjša števila dosegajo stranke tipa “*Creative Agency*”, “*Celtra Internal*” (testne kampanje podjetja Celtra d.o.o), “*SSP*”, “*Trafficking / Ad Ops*”. Odločili smo se, da preverimo tudi moč vsakega vzorca podatkov, da dobimo informacijo še o številu kampanj glede na tip stranke. Za ta namen smo prešteli število kampanj za vsak tip stranke in podatke prikazali s histogramom (slika 3.3).



Slika 3.2: Število prikazov kampanj glede na tip stranke.



Slika 3.3: Število kampanj glede na tip stranke.

Iz slike 3.3 je razvidno, da je največji del kampanj v lasti strank tipa “*Ad Network*” (22.181 kampanj) ali “*Publisher*” (32.385 kampanj). Tipa strank “*SSP*” (26 kampanj) in “*Trafficking / Ad Ops*” (20 kampanj) imata zane-marljivo število kampanj. Vse podatke smo na koncu združili v tabelo 3.1.

Tip stranke	Število kampanj	Število prikazov kampanje	
		Povprečje	Mediana
Ad Network	22.181	3.704.407	920.560
Advertiser / Brand	2.048	28.605.604	6.641.140
Agency Group	1.599	2.914.677	794.560
Celtra Internal	2.260	736.384	452
Creative Agency	399	2.214.962	131.847
DSP	8.381	4.405.302	1.594.102
Media Agency	5.829	5.143.008	1.018.584
Other	664	27.282.688	324.961
Publisher	32.385	1.297.292	241.544
SSP	26	8.712	149
Trafficking / Ad Ops	20	2.226.654	473

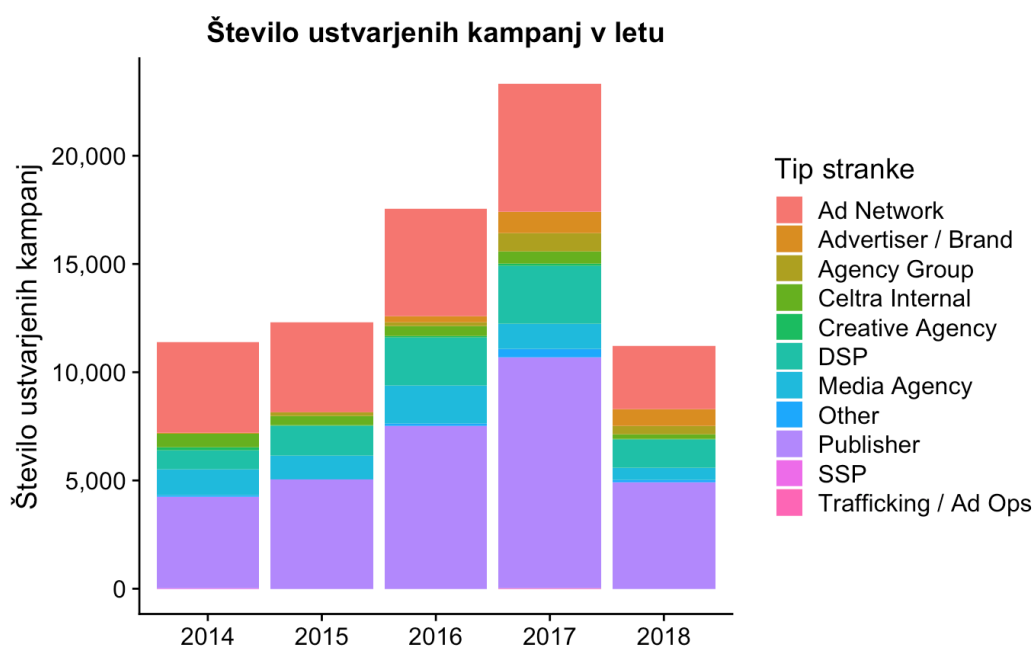
Tabela 3.1: Podatki o številu kampanj in številu prikazov

Kampanje strank tipa “*Advertiser / Brand*” imajo tako v povprečju, predvsem pa v mediani, veliko več prikazov kot kampanje ostalih tipov strank. Zanimiv je podatek o povprečnem številu prikazov kampanj strank tipa “*Other*,” ki se od mediane razlikuje za skoraj 27.000.000. To je smiselno, saj pod tip “*Other*” spadajo kampanje, ki ne pripadajo drugim tipom in so si med sabo različne, kar privede do velikih razlik med števili prikazov kampanj.

3.2 Sprememba sestave kampanj skozi čas

V drugem delu analize smo se osredotočili na leto, v katerem je bila kampanja ustvarjena. S tem smo si lahko ogledali način oglaševanja oziroma lastnosti

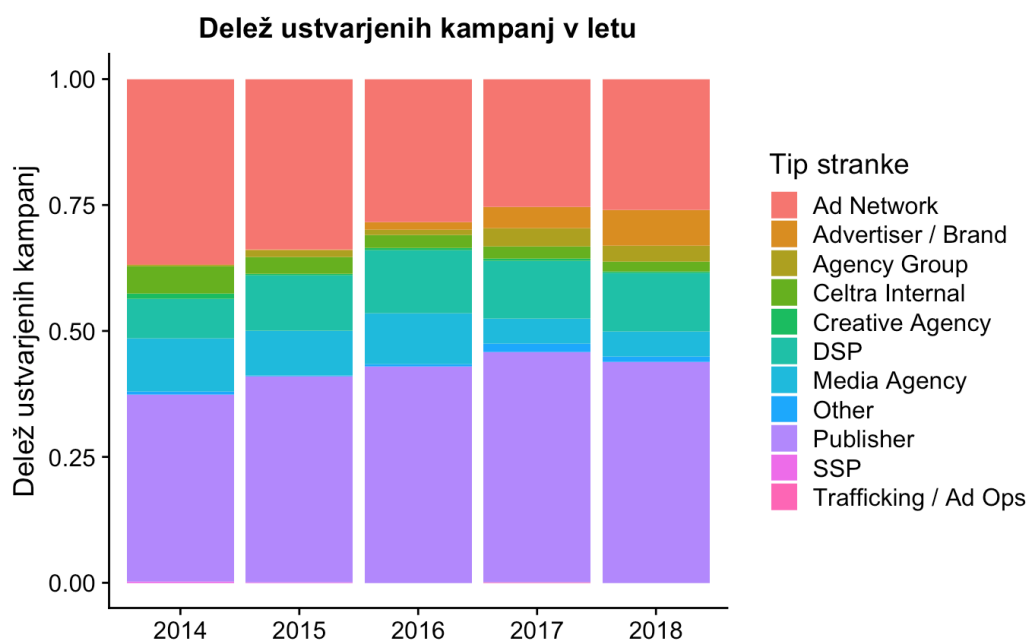
kampanj po letih in preverili, ali so se zgodile kakšne spremembe tekom let. Kot že omenjeno, so podatki v razponu od 1. 1. 2014 do 29. 6. 2018. Za leto 2018 smo imeli, temu primerno, podatke le za nekaj več kot polovico leta. Za začetek smo se lotili pregleda števila kampanj po letih. Sešteli smo kampanje in jih razdelili po tipih strank.



Slika 3.4: Število ustvarjenih kampanj med leti 2014 in 2018.

Opazna je rast števila kampanj skozi leta (slika 3.4). V letu 2018 je bilo do 29. 6. ustvarjenih približno polovico toliko kampanj (11.205) kot v letu 2017 (23.332). Glede na to, da vemo, da je število novih kampanj v različnih delih leta podobno, lahko ta podatek nakazuje na morebitno počasnejšo rast števila kampanj, kot v prejšnjih letih. V drugem histogramu (slika 3.5), ki ima vertikalno skalo prilagojeno na odstotke, ni velikih posebnosti. Opazimo, da se je pomanjšal delež kampanj strank tipa “*Ad Network*” in “*Media Agency*”, delež kampanj strank tipa “*Advertiser / Brand*” in “*Publisher*” pa se je povečal.

Podatke smo se odločili prikazati tudi ločeno po letih in številu prikazov

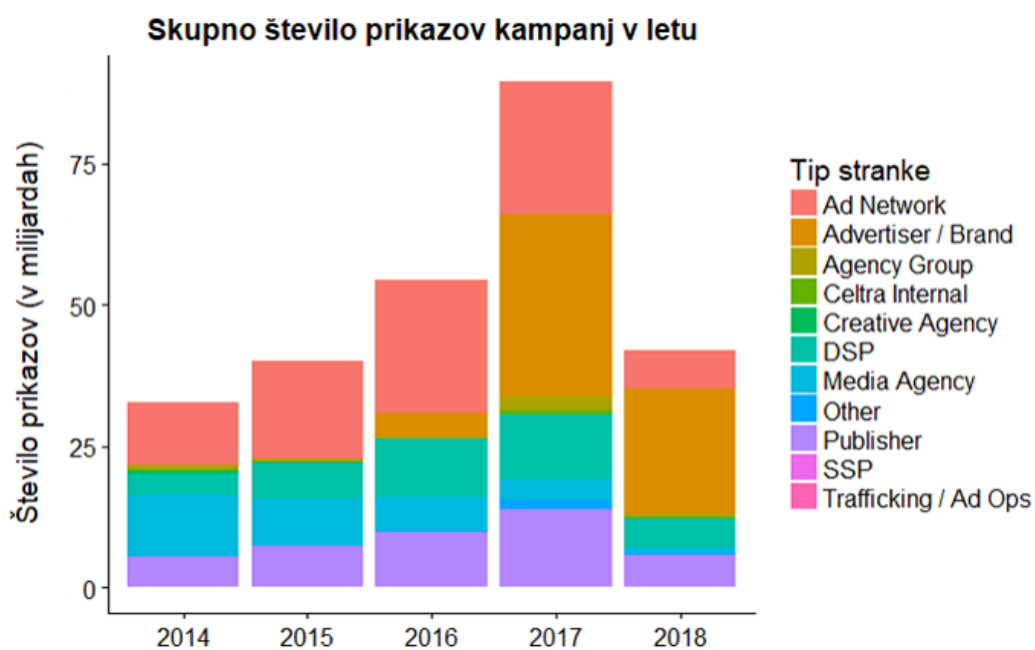


Slika 3.5: Deleži ustvarjenih kampanj med leti 2014 in 2018.

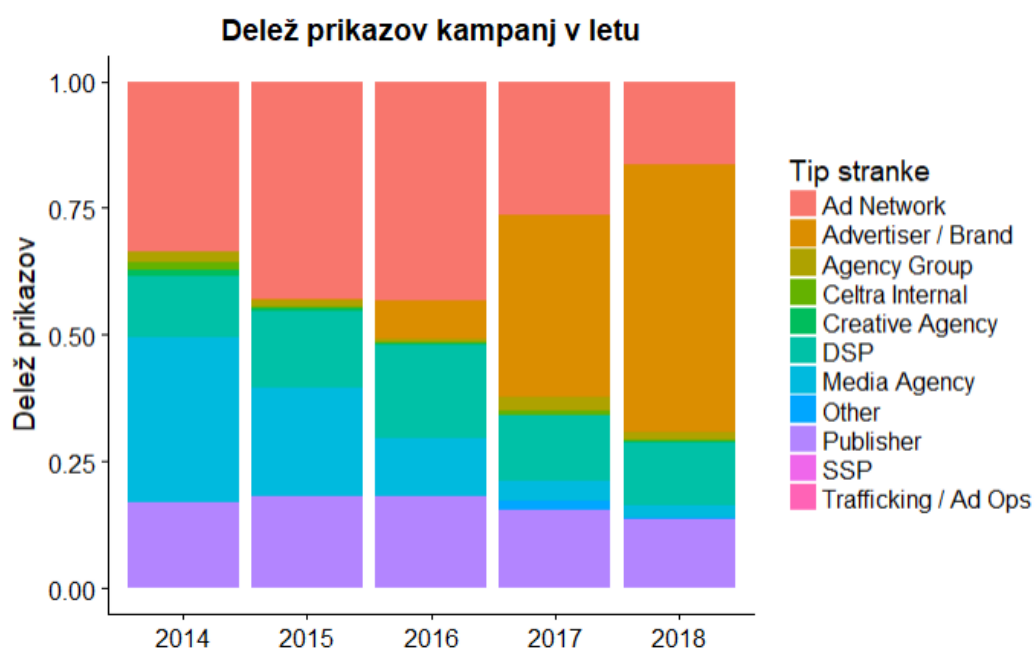
kampanj. Histograma prikazujeta podatke na enak način kot vizualizaciji iz prejšnjega dela (sliki 3.4 in 3.5), le da smo namesto števila kampanj na vertikalni osi prikazali skupno število prikazov, ki so ga kampanje imele vsako leto.

V primerjavi s sliko 3.4, je iz slike 3.6 takoj razvidno, da so tekom let stranke tipa “*Advertiser / Brand*” povečale število kampanj in prikazov, vizualizacija na sliki 3.7 to le še dodatno potrди. Skupno število prikazov kampanj strank tipa “*Advertiser / Brand*” je v letu 2016 začelo rasti, leta 2017 je to število doseglo približno tretjino vseh prikazov v letu, leta 2018 pa presegle polovico in s tem predstavljalo veliko večino vseh prikazov. Analizirali smo še mediano in povprečno število prikazov kampanj za vsako leto posebej in dobili rezultate prikazane na slikah 3.8 in 3.9.

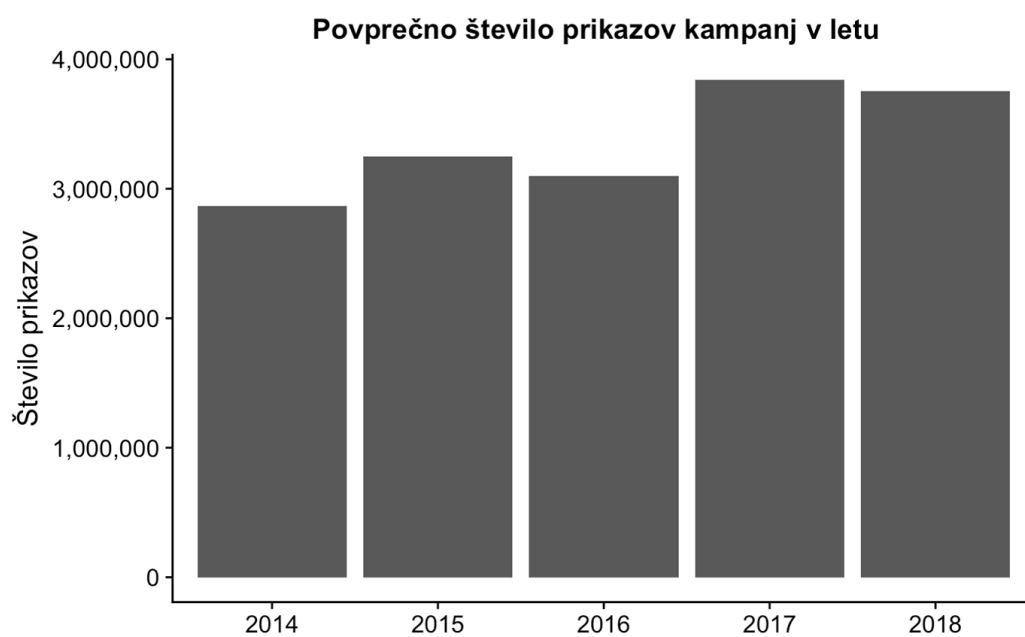
Zanimivo je dejstvo, da z leti povprečno število prikazov na kampanjo raste medtem, ko mediana le-teh, pada vsaj od leta 2015. Razlog za visoko povprečje leži predvsem v kampanjah strank tipa “*Advertiser / Brand*,” ki jih je malo, a dosegajo najvišja števila prikazov na kampanjo. Ostali tipi strank



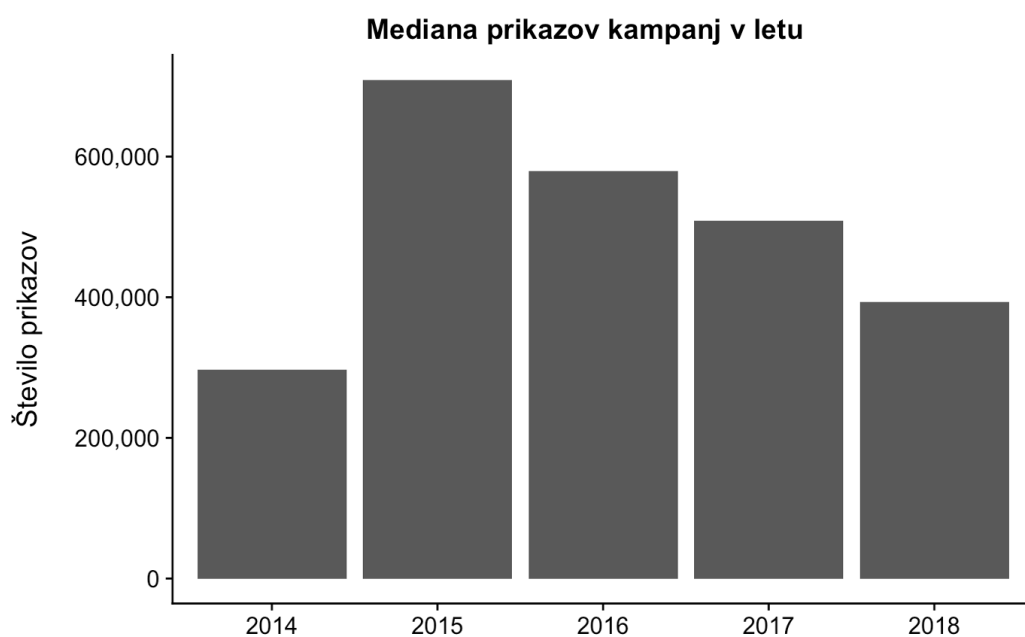
Slika 3.6: Število prikazov kampanj med leti 2014 in 2018.



Slika 3.7: Deleži skupnih prikazov kampanj med leti 2014 in 2018.



Slika 3.8: Povprečno število prikazov kampanj med leti 2014 in 2018.



Slika 3.9: Mediana prikazov kampanj med leti 2014 in 2018.

pa v večini, ravno nasprotno, dosegajo manjša števila prikazov na kampanjo in ustvarjajo veliko testnih kampanj.

V nadaljevanju smo zgradili podatkovno množico še na natančnost enega meseca in si pogledali podatke o številu novih kampanj ter številu prikazov kampanj razdeljenih po mesecih. Ugotovili smo, da med leti 2015 in 2017 ni prišlo do velikih razlik, opazen je le manjši dvig števila novih kampanj okoli meseca maja in oktobra.

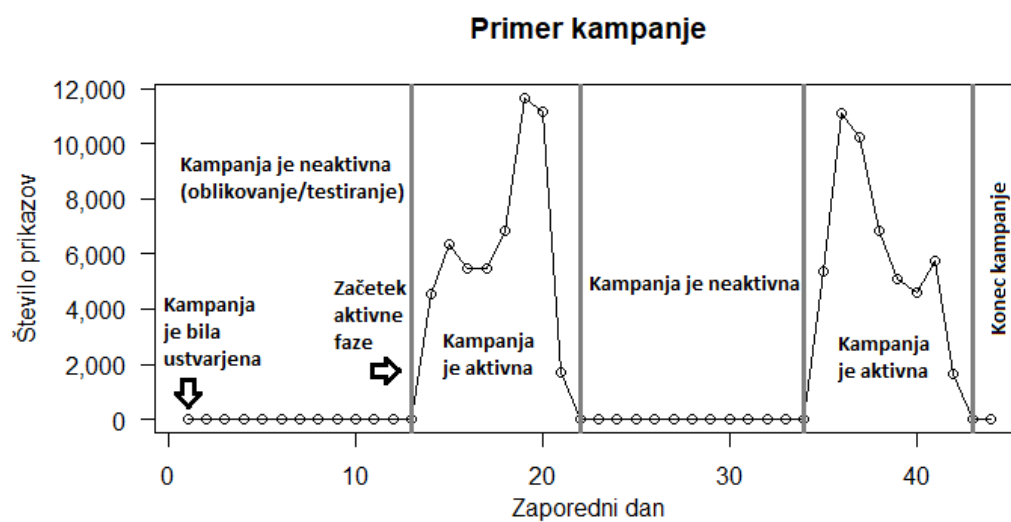
3.3 Porazdelitev časa izvajanja kampanj

Podatki, ki smo jih imeli na voljo v končni podatkovni množici, so vsebovali podatke od dneva, ko je bila kampanja ustvarjena, do dneva, ko je imela zadnji prikaz. Kampanja gre pred začetkom svoje aktivnosti na spletu čez določene stopnje. Ponavadi vsebuje časovno obdobje, kjer so oblikovalci izdelovali spletne oglase. Za tem lahko sledi obdobje, ko je kampanja v testni fazi. Kadarkoli vmes pa so lahko dnevi, ko se s kampanjo ne dogaja nič. Lep primer tega so vikendi, saj takrat ljudje niso v službah in se posledično oblikovanje oglasov oziroma testiranje kampanje za nekaj dni ustavi. Slika 3.10 prikazuje eno od kampanj z označenimi obdobji.

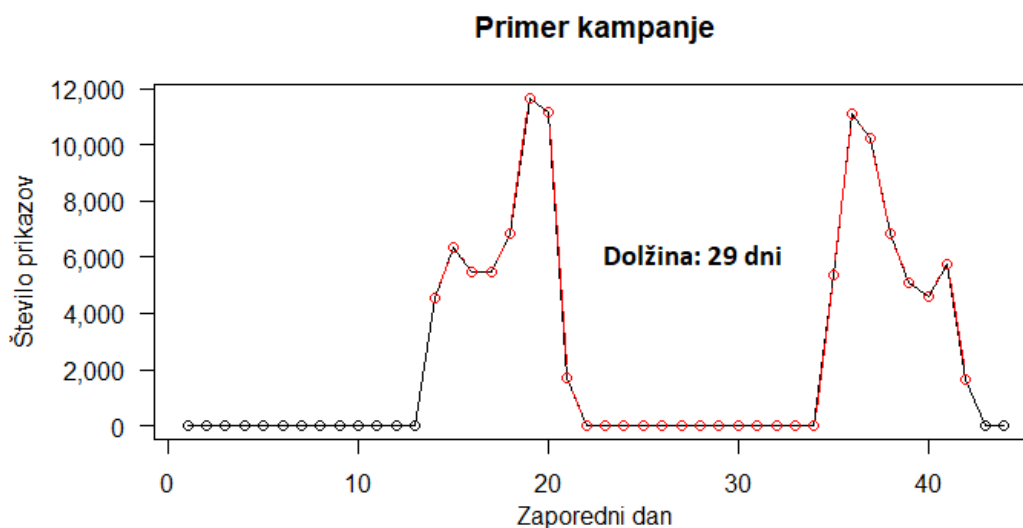
Ko govorimo o dolžini kampanje, nam vse zgoraj omenjene stvari postavijo vprašanje o tem, kako je dolžina kampanje sploh definirana. Za potrebe naše analize smo se odločili, da nam stopnja gradnje kampanje, testna obdobja in obdobja neaktivnosti pred začetkom aktivnosti kampanje ne predstavljajo uporabnih podatkov. Dolžino kampanje smo na začetku definirali na dva različna načina:

- dnevi od začetka aktivnosti kampanje do njenega konca, vključno z vsemi vmesnimi obdobji neaktivnosti (slika 3.11),
- dnevi od začetka aktivnosti kampanje do njenega konca, brez obdobji vmesnih neaktivnosti (slika 3.12).


Obe definiciji dolžine kampanje sta na svoj način pravilni. Prva predstavlja skupno trajanje kampanje, druga pa efektivno dolžino kampanje. Za naš



Slika 3.10: Primer kampanje z označenimi obdobji.



Slika 3.11: Dolžina kampanje vključno z obdobji neaktivnosti.



Slika 3.12: Dolžina kampanje brez obdobj neaktivnosti.

namen smo se odločili, da je bolj primerna prva definicija. Eden od razlogov je bil, da so kampanje večinoma brez vmesnih neaktivnih faz. Potrebovali smo še način omejevanja časovne vrste, da smo lahko izločili obdobje pred začetkom aktivnosti in obdobje po koncu aktivnosti. Po različnih poskusih omejitve smo prišli do treh možnosti.

1. Kampanje z več kot 50.000 prikazi, omejene:
 - od dneva, ko je kampanja dosegla svojih prvih 10.000 prikazov,
 - do dneva, ko je dosegla svojih zadnjih 10.000 prikazov.

2. Kampanje z več kot 50.000 prikazi, omejene:
 - od dneva, ko je kampanja dosegla svojih prvih 10.000 prikazov ali prikaz, ki predstavlja prvih 5 % vseh prikazov kampanje,
 - do dneva, ko je dosegla svojih zadnjih 10.000 prikazov, ali prikaz, ki predstavlja zadnjih 5 % vseh prikazov kampanje.

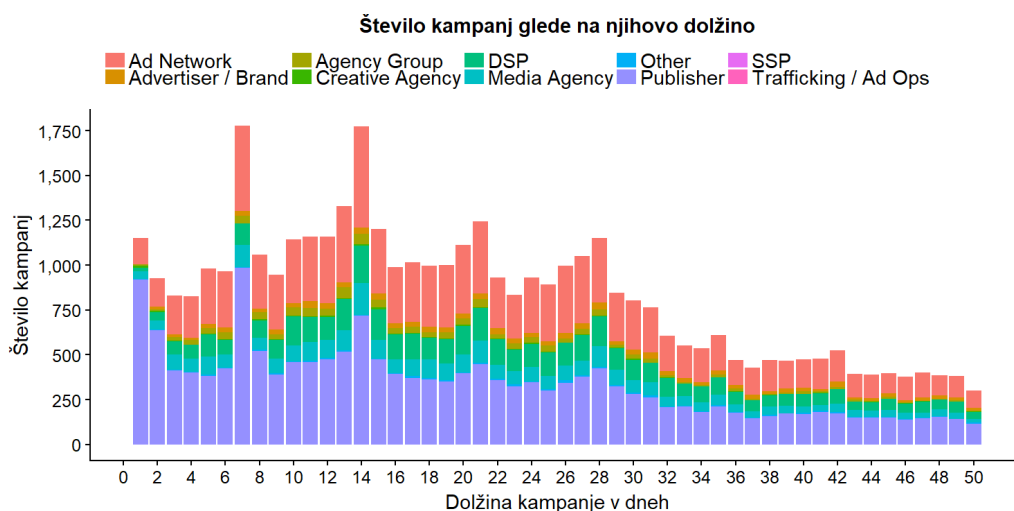
3. Kampanje z več kot 50.000 prikazi, omejene:
 - od dneva, ko je kampanja prvič preseгла 1.000 prikazov v dnevu,
 - do zadnjega dneva z isto lastnostjo.

Vse navedene možnosti so množico omejile na drugačen način. Prva možnost je množico omejila dobro, težave so se pojavile le pri kampanjah s številom prikazov blizu meje 50.000, kjer je pri določenih kampanjah vrednost prvih 10.000 prikazov množico na začetku omejila prepozno. Izboljšava prve možnosti je bila druga možnost, ki je manjše kampanje omejila prej (pri prvih 5 % vseh prikazov kampanje), večje kampanje pa so ostale omejene pri meji 10.000. Tretja možnost jih je prav tako dobro omejila, vendar je bila občutljiva na kampanje, ki so imele v testnih fazah veliko prikazov na dan.

Po preizkusu vseh zgoraj naštetih možnosti smo se na koncu odločili za uporabo druge (slika 3.11). Ta je namreč najboljše omejila časovno vrsto kampanje le na dneve od začetka aktivne faze do konca kampanje. Dolžino kampanje smo tako definirali od dneva, ko je kampanja dosegla svojih prvih 10.000 prikazov, ali prikaz, ki predstavlja prvih 5 % vseh prikazov kampanje, do dneva, ko je dosegla svojih zadnjih 10.000 prikazov ali prikaz, ki predstavlja zadnjih 5 % vseh prikazov kampanje. Na tej točki smo izločili kampanje strank tipa “*Celtra Internal*”, ker gre za pretežno testne kampanje oziroma kampanje, ki so bile ustvarjene za interne potrebe podjetja Celtra d.o.o in nam ne podajo uporabnih informacij glede dolžine kampanj.

Analizo smo začeli z ugotavljanjem distribucije dolžin kampanj. Vsem kampanjam smo določili število dni glede na izbran način definicije dolžine. Podatke smo prikazali s histogramom (slika 3.13), ponovno obarvane glede na tip stranke.

Vizualizacija podatkov na sliki 3.13 nas pripelje do zanimive ugotovitve. Vrhovi v histogramu se konsistentno pojavljajo na točkah, ki predstavljajo število dni deljivo s 7, izjema so kampanje dolžine enega dneva. Razvidno je, da so najbolj pogoste kampanje dolžine enega ali dveh tednov. Po pregledu vzorca kampanj dolžine sedmin dni se je izkazalo, da jih je veliko število del večjih kampanj. Podjetje lahko namreč ob spremembi izgleda oglasov oziroma drugih spremembah odloči, da namesto spremembe oglasa ustvarijo povsem novo kampanjo, kar se je izkazalo za pogosto odločitev. Iz teh ugotovitev lahko zaključimo, da je obdobje enega ali dveh tednov najbolj

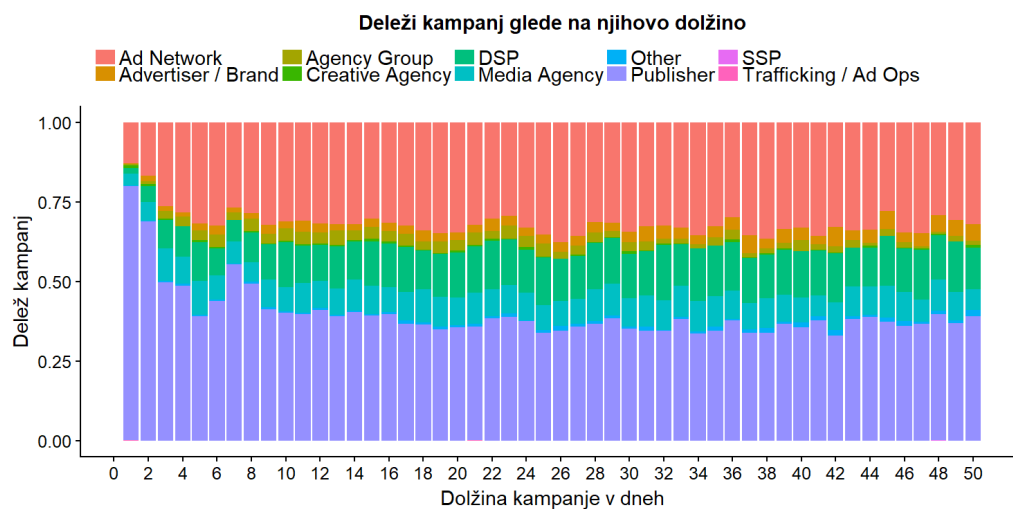


Slika 3.13: Število kampanj glede na njihovo dolžino.

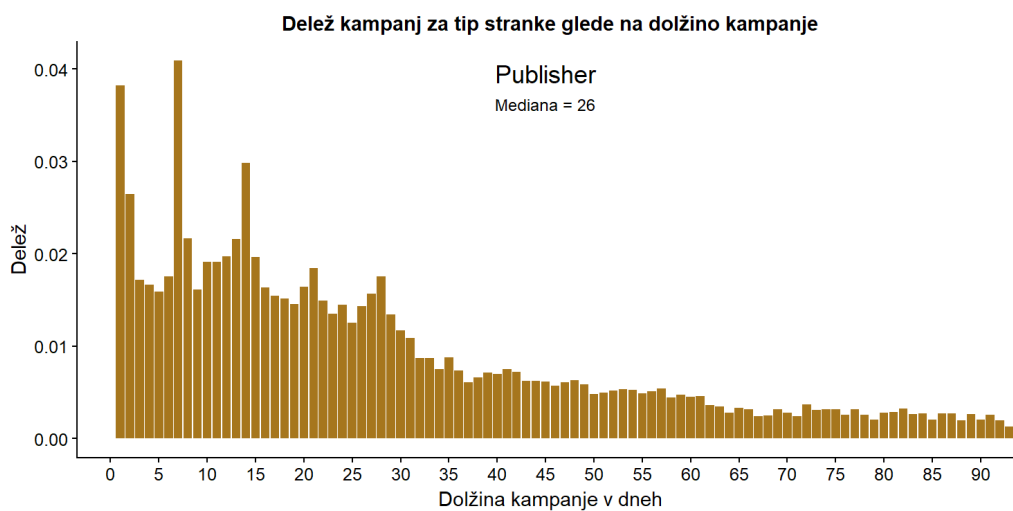
pogosta dolžina kampanj. V še več primerih je to tudi čas aktivnosti ene različice kampanje preden jo nasledi posodobljena oziroma popolnoma spremenjena kampanja z istim namenom. Sledil je pregled po odstotkih vsakega tipa stranke (slika 3.14).

Stranke tipa “*Publisher*” na sliki 3.14 predstavljajo veliko večino kampanj dolžine enega in dveh dni, prav tako predstavljajo večji del kampanj dolžine enega tedna. Po dolžini osmih dni se distribucija stabilizira, v splošnem imajo večji del kampanj v lasti stranke tipa “*Publisher*” in “*Ad Network*.” Sledijo jim stranke tipa “*DSP*” in “*Media Agency*,” ostale kampanje pa se razdelijo med druge tipe strank. Kampanje smo razdelili še za vsak tip stranke posebej in izračunali delež kampanj vsakega tipa stranke za vsako dolžino dni. Da bi prikazali le tipe strank z zadostnim številom kampanj za dovolj informativno vizualizacijo, smo prikazali le histograme za tipe strank z več kot 250 kampanjami po filtriranju množice (tipov strank “*SSP*” in “*Trafficking / Ad Ops*” tako zaradi premajhnega števila kampanj nismo analizirali). Dodali smo še mediano dolžine kampanj in podatke vizualizirali.

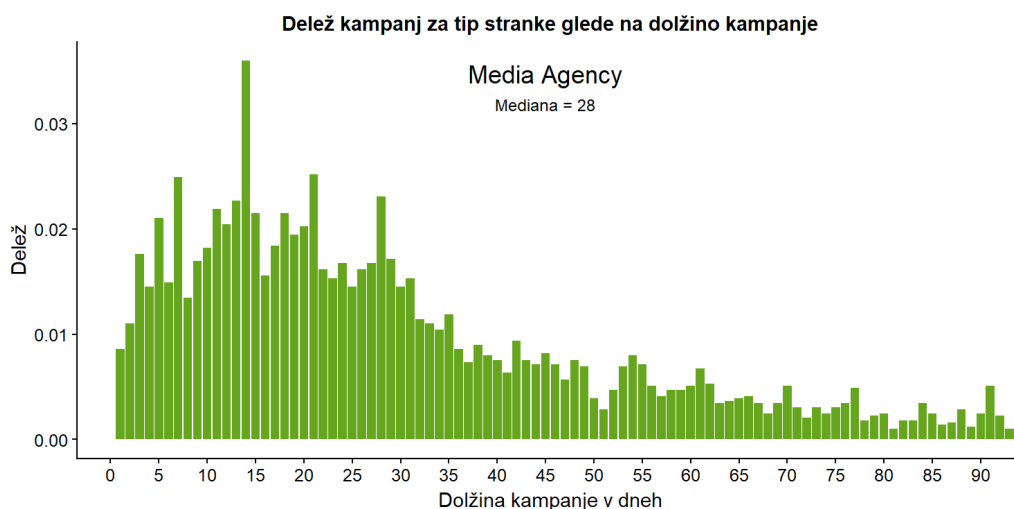
Stranke tipa “*Publisher*” (slika 3.15) imajo, kot že omenjeno, velik del kampanj dolžine enega in dveh dni, kar histogram le še potrди. Mediana



Slika 3.14: Deleži kampanj po tipih strank glede na dolžino kampanj.



Slika 3.15: Deleži kampanj po tipih strank glede na dolžino kampanj - “*Publisher*.”




Slika 3.16: Deleži kampanj po tipih strank glede na dolžino kampanj - “Media Agency.”

je kljub temu precej visoka (26 dni), za kar poskrbi veliko število daljših kampanj.

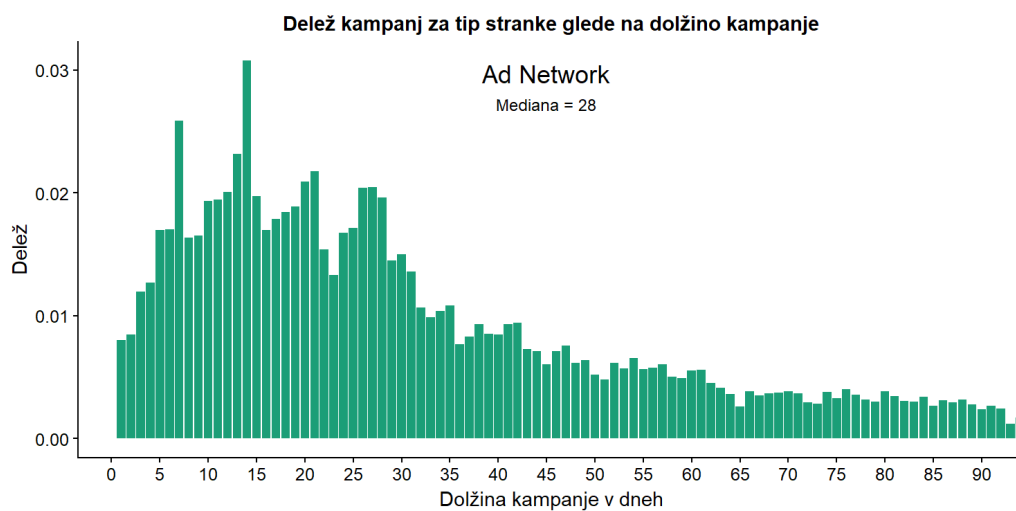
Histogrami strank tipa “Media Agency” (slika 3.16), “DSP” (slika 3.17) in “Ad Network” (slika 3.18) se izkažejo za podobne. Vse imajo največ kampanj dolžine 14 dni in vrhove pri enem, treh in štirih tednih. Prav tako imajo zelo podobno vrednost mediane, (“Media Agency” - 28 dni, “DSP” - 30 dni, “Ad Network” - 28 dni).

Stranke tipa “Agency Group” (slika 3.19) so na prvi pogled podobne strankam tipa “Media Agency”, “DSP” in “Ad Network.” Ob natančnejšemu pregledu distribucije smo ugotovili, da je večina kampanj v območju med 10 in 60 dni. Kampanje strank tipa “Agency Group” pa so večinoma dolge med 10 in 40 dni. Temu primerna je tudi najnižja mediana (21 dni).

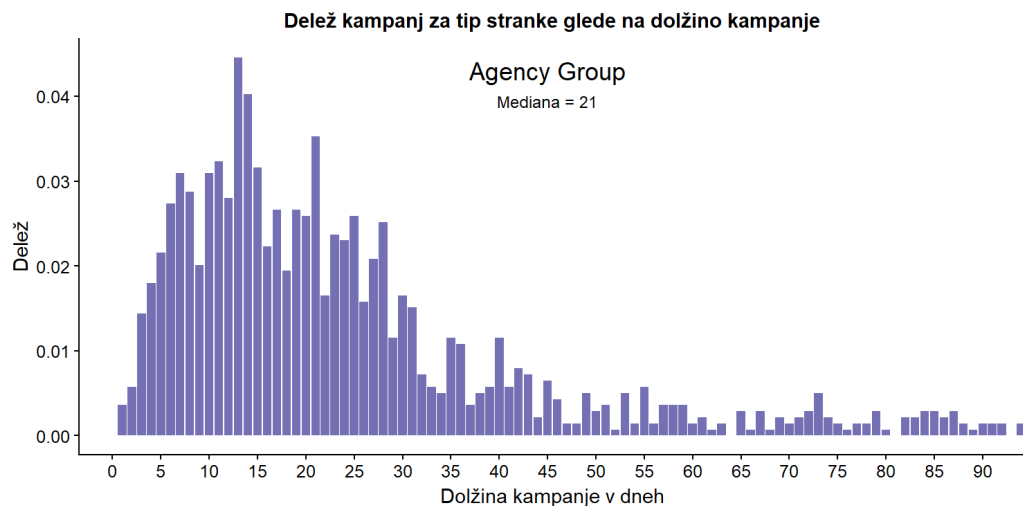
Zanimiv je tudi histogram strank tipa “Advertiser / Brand” (slika 3.20), kjer se opazi znatno povečanje daljših kampanj v primerjavi s prej omenjenimi tipi strank. Generalno daljše kampanje podpre tudi precej višja mediana (38 dni), prav tako pa opazimo, da se vrhovi pojavljajo tudi po dolžini tridesetih dni. Distribucija kampanj nam ob natančnejši analizi pove, da večina



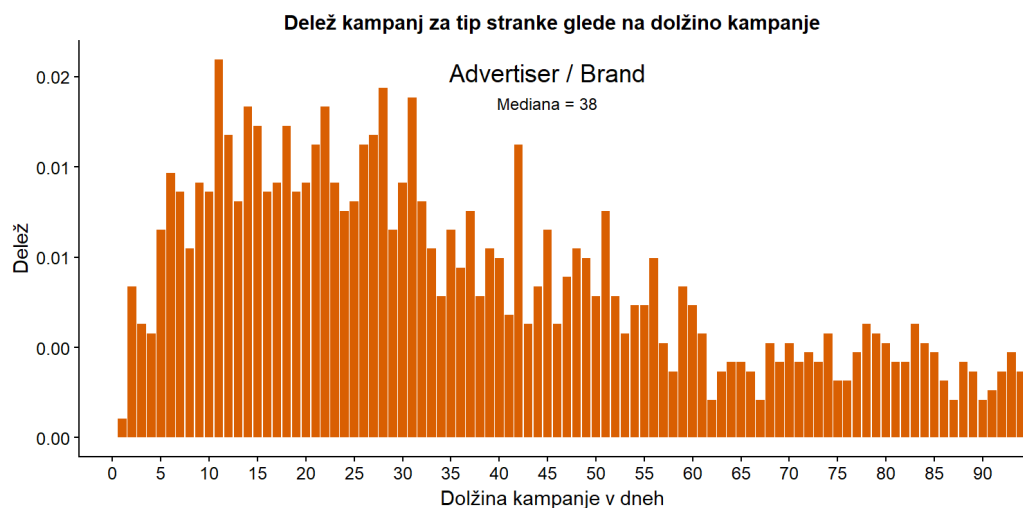
Slika 3.17: Deleži kampanj po tipih strank glede na dolžino kampanj - “*DSP*.”



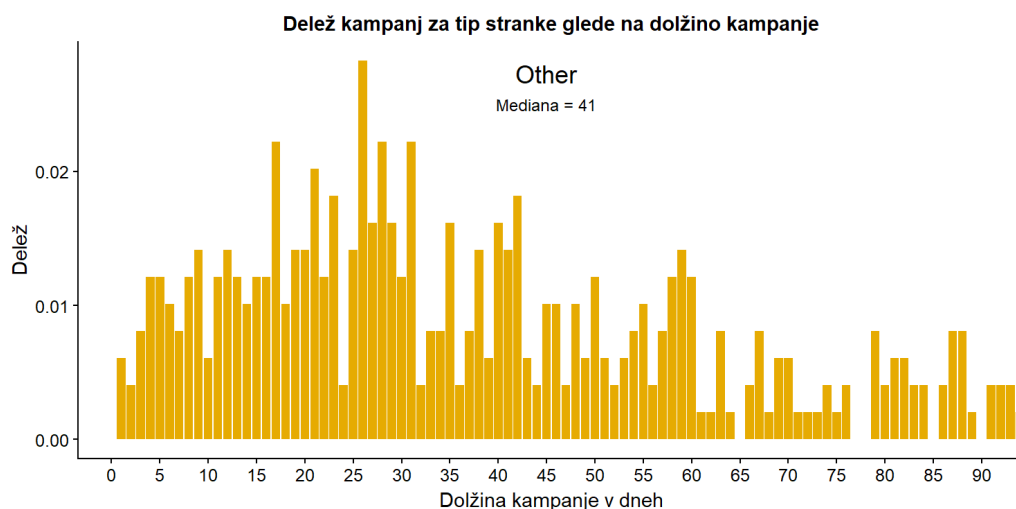
Slika 3.18: Deleži kampanj po tipih strank glede na dolžino kampanj - “*Ad Network*.”



Slika 3.19: Deleži kampanj po tipih strank glede na dolžino kampanj - “Agency Group.”



Slika 3.20: Deleži kampanj po tipih strank glede na dolžino kampanj - “Advertiser / Brand.”




Slika 3.21: Deleži kampanj po tipih strank glede na dolžino kampanj - “*Other*.”

kampanj leži na območju med približno 20 in 75 dni, kar je tudi opazno več kot pri ostalih prej omenjenih tipih strank. Kot že omenjeno v prejšnjih oddelkih, so taki rezultati na nek način tudi pričakovani, saj kampanje strank “*Advertiser / Brand*” dosegajo največja števila prikazov in so temu primerno tudi v večini daljše.

Ostane nam le še vizualizacija strank tipa “*Other*” (slika 3.21). To so kampanje vrst strank, ki nimajo določenega opisa in tako iz teh podatkov ne moremo pridobiti veliko uporabnih informacij. Opazimo lahko, da so kampanje v večini daljše, vrh se pojavi pri 26 dneh, mediana pa je v tem primeru celo večja od strank tipa “*Advertiser / Brand*.”


Želeli smo preveriti, ali obstaja povezava med dolžino kampanj in številom prikazov kampanje. Združili smo podatke o številu prikazov in dolžini kampanj, dobljeno množico pa nato razdelili na pet delov. To smo naredili tako, da smo vse kampanje uredili padajoče po številu prikazov in vzeli 20 % kampanj z največ prikazi, nato naslednjih 20 % in tako dalje dokler nismo prišli do 20 % kampanj z najmanjšim številom prikazov. Izrisali smo pet histogramov (slike 3.22 do 3.26), za vsako podmnožico posebej, prav tako smo za




Slika 3.22: Število kampanj glede na njihovo dolžino - skupina 1 (prva skupina, 20 % kampanj z najmanj prikazi).

boljšo preglednost obarvali števila dni, ki so deljiva s 7.

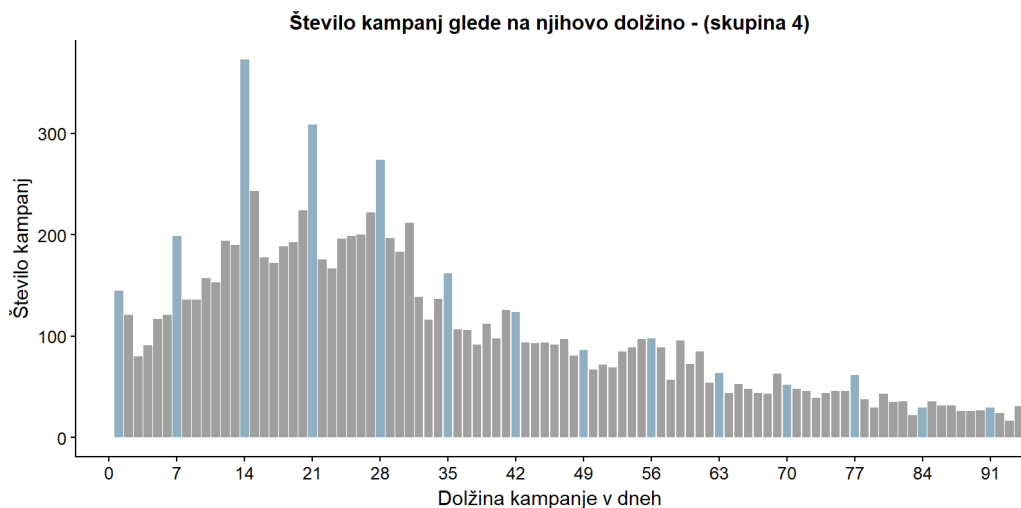
Naša pričakovanja o povezavi števila prikazov in dolžine so se potrdila. Ob primerjavi histogramov (slike 3.22 do 3.26) je bilo očitno, da so kampanje z več prikazi v glavnem tudi daljše. Prav tako se ohranjajo vrhovi histogramov na dnevih deljivih s 7. Kampanje z največ prikazi (slika 3.26) imajo tako očitne vrhove na dolžinah tudi 42 dni oziroma 6 tednov. Večinski delež kampanj se potem z vsako naslednjo podmnožico pomakne proti manjšim številkam, prav tako se postopoma premikajo vrhovi histogramov, kjer se pri zadnji podmnožici (slika 3.22) ustavijo na vrednostih okoli 1, 7 in 14 dni.



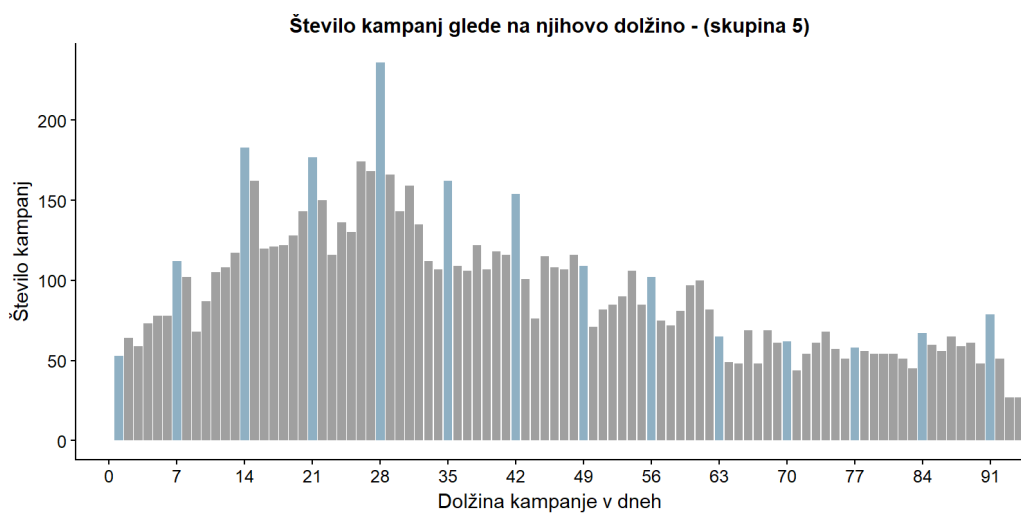
Slika 3.23: Število kampanj glede na njihovo dolžino - skupina 2 (druga skupina po številu prikazov naraščajoče).



Slika 3.24: Število kampanj glede na njihovo dolžino - skupina 3 (srednja skupina).



Slika 3.25: Število kampanj glede na njihovo dolžino - skupina 4 (četrta skupina po številu prikazov naraščajoče).



Slika 3.26: Število kampanj glede na njihovo dolžino - skupina 5 (zadnja skupina, 20 % kampanj z največ prikazi).

Poglavje 4

Napovedovanje števila prikazov kampanj

V zadnjem delu diplomske naloge smo preverili, kako dobro lahko napovemo prikaze kampanje. Gradili in vrednotili smo modele, ki napovedujejo število prikazov v petem dnevu kampanje.

4.1 Podatki

Naprej smo izločili vse kampanje strank tipa “*Celtra Internal.*” Le-te so namenjene izključno za interno uporabo podjetja Celtra d.o.o., predvsem za potrebe testiranja in nam ne podajo uporabnih podatkov. Iz preostalih podatkov smo sestavili podatkovno množico, ki vsebuje:

Podatkovna množica
Atributi:
Campaign ID
Client type
Day 1 sessions
Day 1 cumulative sessions
Day 1 rolling share
Day 2 sessions
Day 2 cumulative sessions
Day 2 rolling share
Day 3 sessions

Day 3 cumulative sessions
Day 3 rolling share
Day 4 sessions
Day 4 cumulative sessions
Day 4 rolling share
Day 5 sessions

Opis atributov:

Day x sessions - število prikazov v dnevu

Day x cumulative sessions - vsota prikazov do tega dne

Day x rolling share - delež prikazov kampanje v dnevu
od vseh prikazov do tega dne

Poleg že pridobljenih atributov smo dodali še atribut tekočega deleža, ki pove delež prikazov kampanje v določenem dnevu od vseh prikazov do tega dne, izračunano po formuli: *število prikazov v dnevu / vsota prikazov do vključno tega dne*. Izbira prvega dne je vsekakor pomembna. Preizkusili smo tri različne možnosti in temu primerno smo zgradili tri podatkovne množice z začetnim dnevom:

- (a) dan, ko je bila kampanja ustvarjena,
- (b) dan, ko je imela kampanja prvič 1.000 ali več prikazov,
- (c) dan, ko je vsota prikazov dosegla oziroma preseгла 10.000.

4.2 Metode

Preizkusili smo naslednje metode strojnega učenja:

- linearna regresija,
- regresijsko drevo,
- naključni gozdovi,
- metoda podpornih vektorjev,
- k najbližjih sosedov.

Za vrednotenje uspešnosti smo izvajali petkratno prečno preverjanje. Uspešnost pridobljenih modelov smo ocenili z:

- MAE - povprečna absolutna napaka,
- RMAE - relativna povprečna absolutna napaka, glede na povprečno vrednost,
- RMSE - relativna povprečna kvadratna napaka.

4.3 Rezultati

Rezultati vrednotenja so prikazani v tabelah 4.1, 4.2 in 4.3. Tabela 4.1 prikazuje rezultate na prvi množici (začetek z dnevom kreacije kampanje). Le-ti so se izkazali za najslabše. Razlog je verjetno obdobje v katerem so kampanje na tej točki. Veliko kampanj je še v začetni fazi gradnje in testiranja, nekatere pa so že aktivne. Nasploh so podatki precej nepredvidljivi in zato težji za napovedovanje.

model	MAE	RMAE	RMSE
Linearna regresija	37.847,98	0,65	1,05
Regresijsko drevo	45.092,96	0,77	1,10
Naključni gozdovi	33.584,34	0,62	1,00
Metoda podpornih vektorjev	68.332,20	1,19	0,97
K najbližjih sosedov	34.742,65	0,64	3,37
Povprečje (konst. regresor)	57.124,68		

Tabela 4.1: Podatkovna množica 1 - začetek z dnevom, ko je bila kampanja ustvarjena.

V drugi in tretji množici (tabeli 4.2 in 4.3) smo, zanimivo, dobili boljše a precej podobne rezultate. Povprečna relativna povprečna absolutna napaka (RMAE) je pri drugi množici 0,45, pri tretji pa 0,46. To nam pove, da je ob postavljenih smiselnih mejah glede števila prikazov, napovedovanje bolj uspešno. Prav tako se s tem v veliki večini izognemo neaktivnim fazam kampanje in do neke mere tudi izključno testnim kampanjam. Napaka je sicer še vedno velika, ampak znatno manjša od napovedovanja s povprečno vrednostjo ali od napake pridobljene pri uporabi prve množice. Pri metodah

model	MAE	RMAE	RMSE
Linearna regresija	56.240,72	0,42	0,58
Regresijsko drevo	68.909,67	0,52	0,66
Naključni gozdovi	46.745,04	0,36	0,51
Metoda podpornih vektorjev	63.322,81	0,50	0,65
K najbližjih sosedov	55.229,55	0,44	0,69
Povprečje (konst. regresor)	129.645,27		

Tabela 4.2: Podatkovna množica 2 - začetek z dnevom, ko je imela kampanja prvič 1.000 ali več prikazov.

model	MAE	RMAE	RMSE
Linearna regresija	55.595,15	0,43	0,36
Regresijsko drevo	69.494,98	0,54	0,54
Naključni gozdovi	52.669,74	0,41	0,69
Metoda podpornih vektorjev	64.751,09	0,50	0,72
K najbližjih sosedov	54.709,55	0,42	0,63
Povprečje (konst. regresor)	128.731,07		

Tabela 4.3: Podatkovna množica 3 - začetek z dnevom, ko je vsota prikazov dosegla oziroma presegla 10.000.

učenja smo najslabše rezultate dobili pri uporabi regresijskega drevesa in metode podpornih vektorjev. Za najboljšo se je v glavnem izkazala metoda naključnih gozdov, ki je po meri RMAE povsod dosegla najboljše rezultate. Omembe vredni so tudi rezultati metode linearne regresije, ki so podobni rezultatom metode naključnih gozdov.

Poglavje 5

Zaključek

Z večanjem uporabe spleta za namene oglaševanja se povečuje tudi nabor podatkov iz katerih lahko pridobivamo znanje o načinih oglaševanja in o lastnostih spletnih kampanj. Razumevanje področja je ključnega pomena za uspešnost podjetja, ki je del spletnega oglaševalskega ekosistema. To je bil tudi cilj prvega dela diplomske naloge. Pridobili smo pregled nad podatki spletnih kampanj glede na različne lastnosti le-teh. Rezultati analiz so pokazali kar nekaj zanimivosti in različnih vzorcev, ki se pojavljajo pri spletnih kampanjah. Pridobljeno znanje se lahko uporablja pri interpretaciji podatkov v prihodnosti, planiranju, poslovanju z različnimi strankami in podobno.

V drugem delu diplomske naloge smo se lotili napovedovanja števila prikazov kampanje za določen dan. Izbrali smo časovni interval štirih dni, v katerem smo zbirali podatke o kampanji. Z uporabo regresijskega modela smo nato napovedali število prikazov za prihajajoči, peti dan. Dosegli smo boljše rezultate kot z napovedovanjem s povprečno vrednostjo, seveda pa obstaja še veliko prostora za izboljšave.

Diplomsko nalogo bi lahko nadgradili predvsem z bolj natančnimi podatki. Podatki o številu prikazov po urah bi nam odprli veliko novih možnosti za natančnejšo analizo. Lahko bi se osredotočili tudi na vzorce, ki se pojavljajo tekom dneva. Prav tako bi lahko bolj natančno določili meje pri merjenju dolžine in določanju obdobja kampanje. Natančnejši podatki pa bi

lahko pozitivno vplivali tudi na uspešnost napovednih modelov.

Literatura

- [1] Celtra d.o.o. Dosegljivo: <https://www.celtra.com/>. [Dostopano: 23.8.2018].
- [2] Celtra secures \$15 million funding from Unilever and WPP to drive creative transformation. Dosegljivo: <http://www.businessofapps.com/wp-content/uploads/2017/06/Screen-Shot-2017-06-22-at-7.01.25-AM-1024x556.png>. [Dostopano: 17.9.2018].
- [3] Digital in 2018: Internet users pass the 4 billion mark. Dosegljivo: <https://kepios.com/blog/2018/2/5/digital-in-2018-internet-users-pass-the-4-billion-mark>. [Dostopano: 22.8.2018].
- [4] David S. Evans. The online advertising industry: Economics, evolution, and privacy. *Journal of Economic Perspectives*, 23(3):37–60, September 2009.
- [5] Anindya Ghose and Sha Yang. An empirical analysis of search engine advertising: Sponsored search in electronic markets. *Management Science*, 55(10):1605–1622, 2009.
- [6] Kaj je oglaševanje. Dosegljivo: <https://www.altius.si/altius/koristne-objave/kaj-je-oglasovanje>. [Dostopano: 22.8.2018].
- [7] Reasons why today's market needs digital marketing services. Dosegljivo: <https://www.ading.agency/reasons-why-todays-market-needs-digital-marketing-services/>. [Dostopano: 17.9.2018].

-
- [8] RSG capital: Celtra. Dosegljivo: <http://www.rsg-capital.si/portfelj/celtra-doo>. [Dostopano: 27.8.2018].
- [9] SSKJ: kampanja (ZRC SAZU). Dosegljivo: http://bos.zrc-sazu.si/cgi/a03.exe?name=sskj_testa&expression=kampanja&hs=1. [Dostopano: 27.8.2018].
- [10] Xuerui Wang, Andrei Broder, Marcus Fontoura, and Vanja Josifovski. A search-based method for forecasting ad impression in contextual advertising. In *Proceedings of the 18th International Conference on World Wide Web*, WWW '09, pages 491–500, New York, NY, USA, 2009. ACM.
- [11] Xuerui Wang and Ruofei Bruce Zhang. Forecasting ad traffic based on business metrics in performance-based display advertising, June 21 2012. US Patent App. 12/973,637.
- [12] Wikipedia: Oglaševanje. Dosegljivo: <https://sl.wikipedia.org/wiki/Ogla%C5%A1evanje>. [Dostopano: 22.8.2018].
- [13] Wikipedia: Spletno oglaševanje. Dosegljivo: https://sl.wikipedia.org/wiki/Spletno_ogla%C5%A1evanje. [Dostopano: 22.8.2018].