Načini filtriranja informacija na društvenim mrežama

Martinović, Iva

Undergraduate thesis / Završni rad

2020

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Academy of Arts and Culture in Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Akademija za umjetnost i kulturu u Osijeku**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:251:008139

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

AKADEMIJA ZA UMJETNOST I KULTURU U OSIJEKU

THE ACADEMY OF ARTS AND CULTURE IN OSIJEK

Repository / Repozitorij:

Repository of the Academy of Arts and Culture in Osijek

zir.nsk.hr

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

dabar

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
AKADEMIJA ZA UMJETNOST I KULTURU
ODSJEK ZA KULTURU, MEDIJE I MENADŽMENT
SVEUČILIŠNI PREDDIPLOMSKI
STUDIJ MEDIJSKE KULTURE

IVA MARTINOVIĆ

NAČINI FILTRIRANJA INFORMACIJA NA DRUŠTVENIM MREŽAMA

ZAVRŠNI RAD

MENTOR:
Izv. prof. dr. sc. Vladimir Rismondo

SUMENTOR:
Tomislav Levak

OSIJEK, 2020.

SAŽETAK

Ovaj rad bavi se fenomenom (internetskih) društvenih mreža, kao i filtriranjem informacija koje su, u manjem ili većem obujmu, vidljive medijskim publikama, odnosno korisnicima. U tu svrhu u radu se definiraju i detaljnije objašnjavaju pojmovi kao što su društvene mreže, računalni algoritmi i kodovi, fragmentacija internetskih sadržaja i drugi srodni pojmovi vezani uz navedenu tematiku.

U radu se obrađuju i suvremene pojave i tendencije poput zaštite informacija na društvenim mrežama te političkih i sigurnosnih dimenzija korištenja društvenih mreža. Također, objašnjavaju se razlike između računalnih kodova i algoritama, njihov međusobni odnos te pojave nastale kao posljedica filtracije informacija - „filter mjehurići“ (*filter bubbles*) i „komore jeke“ (*echo chambers*). U radu se prikazuje korištenje algoritama te medijski efekt i medijska izloženost usmjerena korisnicima. Cilj je rada objasniti na koji se način informacije filtriraju i što se događa na društvenim mrežama kao posljedica te filtracije.

Ključne riječi: algoritmi, društvene mreže, kodovi, informacije, „komore jeke“, „filter mjehurići“

ABSTRACT

The paper *Ways of filtering information on social networks* deals with the phenomenon of social networks, as well as filtering information that is, to a greater or lesser extent, visible to us. In order to better understand terms such as algorithms, filter bubbles and echo chambers, the paper will also define terms such as social networks and codes.

The paper will also deal with tendencies such as the protection of information on social networks and the political and security dimensions of the users on social networks. The main part of the paper will explain the differences between codes and algorithms, it will explain their mutual relationship and the phenomena that arose as a result of filtering information - „filter bubbles" and „echo chambers". The paper presents the use of algorithms and the media effect and user-oriented media exposure.

The aim of this paper is to explain how information is filtered and what is created on social networks as a consequence of the filtering.

Keywords: social networks, algorithms, codes, filter bubbles, echo chambers

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

AKADEMIJA ZA UMJETNOST I KULTURU U OSIJEKU

IZJAVA O AKADEMSKOJ ČESTITOSTI

kojom ja_____ potvrđujem da je moj _____rad
diplomski/završni

pod naslovom _____

_____

te mentorstvom _____

rezultat isključivo mojega vlastitog rada, da se temelji na mojim istraživanjima i oslanja na objavljenu literaturu kao što to pokazuju korištene bilješke i bibliografija. Izjavljujem da niti jedan dio završnog rada nije napisan na nedopušten način, odnosno da nije prepisan iz necitiranoga rada, pa tako ne krši ničija autorska prava. Također izjavljujem da nijedan dio ovoga završnog/diplomskog rada nije iskorišten za bilo koji drugi rad pri bilo kojoj drugoj visokoškolskoj, znanstvenoj ili radnoj ustanove.

U Osijeku, _____

Potpis

_____

SADRŽAJ

1. UVOD 1

2. DRUŠTVENE MREŽE 3

3. ZLOUPORABA I ZAŠTITA INFORMACIJA NA DRUŠTVENIM MREŽAMA 6

3.1. Primjer Rusije 8

4. KODOVI I ALGORITMI 10

5. „FILTER MJEHURIĆI“ KAO POSLJEDICA KORIŠTENJA DRUŠTVENIH MREŽA 14

6. „KOMORE JEKE“ KAO POSLJEDICA FILTRIRANJA INFORMACIJA 19

6.1. „Komore jeke“ – medijski efekt i medijska izloženost 23

7. FRAGMENTACIJA INTERNETA 24

8. ZAKLJUČAK 27

9. LITERATURA 29

1. UVOD

Društvena mreža određena kroz paradigmu skupine dvije, tri ili više osoba povijesna je definicija nastala puno ranije od pojave *weba*. Smještena u internetski prostor dobila je novu dimenziju, a time i nadogradnje koje omogućavaju prepoznavanje i upoznavanje svojih korisnika. Pojava društvenih mreža na internetu uvelike je omogućila lakšu, bržu i višesmjernu komunikaciju između korisnika. Osim toga, količina informacija koja se objavljuje, prosljeđuje i izmjenjuje među korisnicima je velika, tako da je njihova praktičnost uvelike pomogla širenju internetskim prostorom i pojavi sve većih i raznovrsnijih društvenih mreža. Značajan preokret dogodio se pojavom Facebooka kada je takav oblik društvene mreže prvi put u povijesti dobio veliku međunarodnu pozornost i u malom vremenu izazvao zanimanje mnogih ljudi.

U ovom radu najprije se definira pojam društvenih mreža te ukratko objašnjava njihov nastanak i razvoj. Nadalje, u radu se obrađuju pojave i tendencije kao što su zaštita informacija na društvenim mrežama i njezine političke i sigurnosne dimenzije u svrhu razumijevanja razmjene informacija te njihove količine u internetskom prostoru. Glavni dio rada posvećen je objašnjavanju računalnih kodova i algoritama te njihovom međusobnom odnosu. Rad se bavi i posljedicama prikupljanja i filtriranja informacija kao što su „filter mjehurići“ i „komore jeke“ (*filter bubbles, echo chambers*).

Cilj je rada upoznavanje s pojmom društvenih mreža, načinom na koji one funkcioniraju te obradom širokoga spektra njihove funkcionalnosti. Također, cilj je i upoznavanje s načinima filtriranja informacija koji se obavljaju pomoću algoritama radi lakšega snalaženja i kontrole informacija pri korištenju, a sve to u svrhu šire preglednosti i kreiranja profila na društvenim mrežama unutar kojega će se prikazivati raznovrsni sadržaj. Rad se bavi definiranjem pojmova nastalih upotrebom i razvojem algoritama te posljedicama korištenja algoritama za korisnike koji se služe filtriranjem.

Tema algoritama, kao i „filter mjehurića” te „komora jeke” još je uvijek poprilično neistražena, kako u Hrvatskoj, tako i u svijetu. Razina njihove uporabe je visoka, u Hrvatskoj znatno manje nego u svijetu. Algoritmi se svakim danom razvijaju sve više, a količina informacija u bazi podataka pojedinih kompanija je prepuna podataka o tome što korisnici klikaju i što im se najviše

sviđa. Iako je teško spriječiti razvoj i razmjenu baze podataka, moguće je znati na kojim razinama se razmjena odvija te na koji način u svrhu čuvanja privatnosti i informacija koje se dijele „na klik”.

2. DRUŠTVENE MREŽE

Definicija društvenih mreža od prije 50 godina uvelike se promijenila s obzirom na današnjicu. Prema rječniku Merriam Webster (2017.) društvene mreže definiraju se kao forma elektroničke komunikacije (kao *web* stranice za društveno povezivanje) kroz koje korisnici stvaraju *online* zajednice kako bi podijelili informacije, ideje, osobno mišljenje i drugi sadržaj (poput fotografija i videa). Ferenčić (2012: 44) razliku društvenih mreža i sredstava javne komunikacije definira kroz pojave masovnih medija koji se zasnivaju na jednosmjernoj komunikaciji; jedan pošiljatelj može poslati poruku velikom broju primatelja koji ne mogu odgovoriti putem istog kanala. Primjeri takvih medija su radio, novine i televizija. Isti autor društvene mreže definira kao oblik dvosmjerne komunikacije između većeg broja korisnika gdje svaki primatelj može odgovoriti na primljenu poruku pod istim uvjetima i putem istog kanala. Boyd i Ellison (2008: 211) društvene mreže definiraju kao „uslugu temeljenu na webu koja omogućuje pojedincima da izgrade javni ili polu-javni profil unutar omeđenog sustava, artikuliraju listu drugih korisnika s kojima dijele vezu i gledaju i koriste vlastiti popis veza i popise veza drugih unutar sustava." Prema definiciji Jacinte i Vitomira Grbavca, društvene mreže postale su globalni komunikacijski fenomen koje su se pojavljivale i nestajale s globalne komunikacijske scene i društvenoga prostora. Oni smatraju da, bez obzira na konfuziju koja nastaje prilikom definiranja što su to društvene mreže, sigurno je to da one postoje već dugi niz godina i da okupljaju ogroman broj ljudi u komunikaciji na određenim interesnim temama (Grbavac i Grbavac, 2014: 207).

Brojni autori, poput Zgrabljić Rotar (2016), društvene mreže danas smještaju u kontekst medija. Zgrabljić Rotar je medije digitalnog doba podijelila u tri skupine koje čine: 1. tradicionalni mediji, 2. konvergirani tradicionalni mediji (novi mediji) te 3. novi novi mediji (2016: 63). Ista autorica navodi: „Novi novi mediji - Wikipedija, YouTube, Facebook, Twitter i druge društvene mreže, nastale su na platformi interneta, a odlika im je da su njihovi korisnici istovremeno i proizvođači sadržaja. Ti mediji počivaju na ideji društvene inteligencije koja oblikuje sadržaje u toj komunikaciji mnogi prema mnogima" (Nada Zgrabljić-Rotar, 2016: 64). Funkcionalnost razmjene informacija na društvenim mrežama jako je velika, kao i komunikacija na društvenim mrežama gdje se ona ne mora nužno odvijati samo dvosmjerno, nego i na više strana u više smjerova. Sadržaj koji korisnik odluči podijeliti s publikom može biti privatan, podijeljen između ljudi koje korisnik odabire te javan, čime se daje prostor za pregledavanje i komentiranje dijeljenoga sadržaja čitavoj skupini korisnika određene društvene mreže.

Grbavac i Grbavac smatraju da se društvenu mrežu u principu može definirati kao uslugu zasnovanu na *Webu* koja dozvoljava pojedincu da napravi (polu)javni profil i u okviru ograničenoga sustava artikulira listu drugih korisnika s kojima dijeli povezanost te vidi i usporedi svoju listu kontakata s onima koje su napravili drugi korisnici unutar sustava (Grbavac i Grbavac, 2014: 206). Ovakva definicija društvenih mreža uklapa se u nekoliko suvremenih pojava i tendencija: povezanost informacija; vidljivost i transparentnost sadržaja koje korisnik odabire; zatim razina utjecaja javnih i polujavnih profila na sadržaj koji će korisniku biti vidljiv na naslovnoj stranici te način na koji je odabran sadržaj koji mu se pojavljuje.
S vremenom su društvene mreže prepoznate kao odličan izvor pronalaska novih kupaca, potrošača kao i korisnika kapitalističkih proizvoda koji nikada brže i jednostavnije nisu mogli doći do proizvoda na tržištu. Marshall (2004) u svojoj postmodernoj teoriji ističe da je digitalna kultura označila „kraj publike“ u smislu pasivnoga promatrača. Ferguson (2004: 137) tvrdi da su korisnici na neki način predstavljali problem ozbiljnoj eliti jer ju je trebalo voditi, štititi i povremeno joj govoriti što treba napraviti (Nada Zgrabljić-Rotar, 2016.: 61). Kao što su tradicionalni mediji poput radija, televizije i novina u određenom trenutku prepoznali svoje čitatelje, slušatelje i gledatelje kao „kupce” usluga koje su oni, kao mediji, odlučili plasirati na svojim platformama, isto se dogodilo i novim novim medijima, u prvom redu društvenim mrežama.

Interaktivnost između medija i korisnika nikada nije bila jednostavnija i brža. Nadalje, niti marketinški svijet nikada se nije brže razvijao, ali isto tako nikada se nisu brže uspijevale otkrivati želje i stvarati potrebe potrošača. Zgrabljić Rotar poziva se na Marshalla koji je pisao o dvjema osnovnim komponentama koje su pri tome najvažnije: „1. dokidanje autoriteta koji distribuira informaciju, 2. više jednakosti među korisnicima. Interaktivnost označava na neki način nastavak interpersonalne komunikacije u novom okruženju i uz pomoć novih tehnologija. Pri tome ne treba zaboraviti snagu medijske industrije novoga doba koja koristi interaktivnost kao marketinški koncept da bi naglasila stil modernog života i modernog građanstva, što je opet u svrhu prodaje modernih tehnoloških naprava i medija.” (Nada Zgrabljić-Rotar, 2016.:61)

Ovakvim načinom pronalaska, širenja i komentiranja informacija, gdje se sve može dogoditi gotovo u milisekundi, nikada nije bilo jednostavnije doći do informacija, pratiti, analizirati i svojevrsno svjedočiti promjenama, ali i aktualnostima u svijetu. S obzirom da je internet neomeđeni, široki prostor bez točno definiranih granica, ne smije se zanemariti i njegova tamna strana. Prilikom kreiranja računa na gotovo svakoj društvenoj mreži korisnik upisuje osobne podatke koji su, prije pojave društvenih mreža, većinom bili strogo čuvani. Ime, prezime, datum i

godina rođenja i drugi podatci, sve do mjesta prebivanja i boravišta, samo su neke od osnovnih informacija koje korisnik mora unijeti. Osim toga, još mu se nudi mnoštvo sporednih informacija koje se korisniku mogu učiniti zanimljivima za ispunjavanje, s obzirom da su postavljene u obliku upitnika ili svojevrsne ankete u svrhu boljega međusobnog upoznavanja korisnika. Sve te informacije koje je korisnik prethodno unio, iako zvuče prilično bezazleno, često mogu koristiti kao informacije određenim marketinškim, državnim, privatnim i javnim agencijama u svrhu prepoznavanja korisnika, vođenja analitike i kreiranja sadržaja i proizvoda koji bi korisniku najviše odgovarali. „Svojim postojanjem i djelovanjem društvene mreže mijenjanju do sada poznati svijet stvarajući društvo prijatelja povezanih zajedničkim interesima i odnosima, a time i podjednakim stavovima spram određenih tvrtki, organizacija, proizvoda, te ih obilježavaju zajedničke navike." (Demeterffy Lančić, 2010.: 162)

3. ZLOUPORABA I ZAŠTITA INFORMACIJA NA DRUŠTVENIM MREŽAMA

Da su društvene mreže veliki društveni potencijal moglo se pretpostaviti nakon pojave MySpacea (2003. godine) i Facebooka (2004. godine). Opće je poznata činjenica da korisnik prilikom prijave, ali i nakon nje, na društvenim mrežama ostavlja svoje osobne podatke, kao i informacije o osobnim interesima, preferencijama, radnim iskustvima i slično. Iako postoje druge brojne prednosti društvenih mreža, nije zanemariva činjenica da se ovakvi podaci nerijetko znaju koristiti u svrhu krađe identiteta, kreiranja profila na drugim stranicama ili jednostavno njihova uzimanja u svrhu prikupljanja, analize i obrade podataka ciljane skupine marketinških projekata. Mato Brautović navodi „Zaštita privatnosti jedan je od ključnih problema upotrebe interneta. Naime, postojeće tehnologije omogućile su da se vrlo jednostavno i gotovo besplatno prikupljaju osobno podaci i nadziru online aktivnosti korisnika, što je plodno tlo za njihovu zloupotrebu" (2007: 28). Dokman, Kuzelj i Malnar (2018: 135) kreiranje profila na društveno-mrežnim servisima impliciraju s prezentacijom svojega „ja" u pripadajućoj komunikaciji gdje korisnik sam odlučuje koje će privatne informacije iznijeti na vidjelo, tj. ostalim korisnicima te hoće li informacije biti istinite. „Profil na društvenoj mreži je refleksija onog što osoba misli da jest, onog što želi biti i onog što misli da drugi žele da bude. Nerijetko dolazi do hiperpersonalne komunikacije kada virtualni komunikator koristi vještine samoprezentiranja u oblikovanju poruka o sebi, tj. razmjenjuje uglavnom pozitivne i pomalo idealizirane informacije o sebi." (Dokman, Kuzelj i Malnar 2018: 135)

Iako su korisnici na društvenim mrežama fizički odsutni jedni od drugih, ovakva vrsta varki vezanih uz kreiranje karaktera većinom je bezazlena te potječe od prirodnog ljudskog poriva da ostavi najbolji mogući dojam o sebi. Ono što često, u želji da njihova stranica s opisom bude što bolja, korisnici zaboravljaju jest da osobni podaci postaju vlasništvo društvene mreže na koju su prijavljeni. Michael Miller navodi kako „zlonamjerni pojedinci mogu izravno napasti vaše računalo, pristupajući sustavu preko neke vrste „zadnjih vrata" (*backdoor*), a zatim mogu krasti i brisati važne podatke ili iskoristiti vaše računalo za iniciranje dodatnih napada na druga računala, mreže ili web stranice. Anonimnost je glavno obilježje interneta. Drugim riječima, korisnik interneta ima slobodu kreirati koliko god korisničkih profila želi. No, s druge strane, sve ili barem većina osobnih informacija koje se prenose internetom mogu se pretraživati, zbog čega je gotovo nemoguće sačuvati privatni život na društvenim mrežama." (2003: 181). Dokman, Kuzelj i Malnar

(2018.) kasnije iznose i jasne činjenice, a to je da ne ulaze svi u online prostor jednako socijalno i informatički pismeni pa je pitanje sigurnosti i problem zaštite privatnosti u fokusu javnosti. Virtualno zlostavljanje te razne prijevare vezane uz krađu identiteta, kreditnih kartica i piratstva mnogo su lakše kroz javno objavljivanje osobnih podataka. „Naime, osobni podaci korisnika postaju vlasništvo društveno-mrežnih servisa jer se svaki podatak može prodati zainteresiranima za pristupanje ciljanoj publici koja će možda kupiti određeni proizvod ili glasati za određenog kandidata na izborima." (Dokman, Kuzelj i Malnar 2018: 135) Autorica Fry (2018.: n.p.) spominje trgovački lanac Tesco koji je prvi otkrio na koji način upoznati kupce. Riječ je o pojavi potrošačkih kartica - plastičnog materijala, veličine i oblika kreditnih kartica, služe kupcima kako bi ostvarili popuste na određene proizvode trgovačkih lanaca. „Na samom početku potrošačka kartica je prikupljala tek osnovne podatke potrošača. Ime, prezime i datum rođenja te je bilježila što kupac prilikom kupnje stavlja u svoju košaricu. Tek nakon sakupljene velike količine podataka Tesco je uvidjeo što potrošači najviše kupuju te je shvatio koliko su vrijedni podatci koji se nalaze na potrošačkim karticama." (Fry, 2018: n.p.) Mogućnost masovne manipulacije tek tada dolazi do izričaja dok sve više trgovačkih lanaca shvaća prednosti potrošačkih kartica.

Dokman, Kuzelj i Malnar nadalje navode kako je zlouporaba društvenih mreža sastavni dio informacijskoga ratovanja u okviru kojeg se društvene mreže koriste za prijenos i razmjenu određenih sadržajnih konstrukata s ciljem obmanjivanja ili utjecanja na određenu skupinu. Thomas Elkjer Nissen (2015: 96-97) tvrdi sljedeće: „Društvene mreže su zloupotrijebljene kad se koriste radi širenja kodova i mijenjanja algoritama s ciljem iniciranja oružanog sukoba. Društvene mreže koriste se za pronalaženje ciljane publike, prikupljanje obavještajnih podataka, psihološke operacije, ofenzivne i obrambene operacije, kao i za zapovjedne i kontrolne aktivnosti." (prema Dokman, Kuzelj i Malnar 2018.: 135)

Često se spominje da se uporaba informacija u negativnom kontekstu na internetu i društvenim mrežama odvija na mikro i makro razini. Mikrorazina zlouporabe obuhvaća virtualno zlostavljanje i lažnu identifikaciju, odnosno krađu identiteta (Dokman, Kuzelj i Malnar 2018: 136). Conry-Murray i Weafer (2005: 3) elektroničko zlostavljanje ili *cyberbullying* definiraju kao nasilje provedeno na internetu i putem mobilnih uređaja. Također, smatraju da dostupnost informacija velikom broju ljudi može dovesti do poticanja grupne mržnje, uhođenja, slanja prijetećih i okrutnih poruka, dječje pornografije i drugo. Upozoravaju i na krađu identiteta pa tako osobni podaci koji su izloženi na društvenim mrežama mogu služiti upravo takvom obliku krađe, odnosno „kopiranju

informacija poput brojeva kreditnih računa, lozinki i osobnih matičnih brojeva.” (prema Dokman, Kuzelj i Malnar 2018: 136)

Nissen (2015) iznosi zaključak u kojem potvrđuje veliku količinu rasprava ili diseminacija generiranih i općenitih sadržaja na društvenim mrežama koje utječu na znanje i percepciju korisnika, odnosno potiču određeno ponašanje uzrokovano društvenim interakcijama unutar društvenih mreža i tako utječu na procese zapažanja korisnika. Juri Balujevski naglašava da „pobjeda u informacijskom ratovanju može imati jednake učinke i biti jednako uspješna kao pobjeda u klasičnom vojnom sukobu jer je utjecaj golem i može paralizirati sve strukture vlasti neprijateljske države” (Russian military admits significant cyber-war effort, 2017), prenose Dokman Kuzelj i Malnar (2018: 137).

3.1. Primjer Rusije

Informacijski ratovi vođeni na internetu nezaobilazni su u današnje vrijeme i odvijaju se u pozitivnom i negativnom kontekstu.. Kao pozitivne primjere mogu se navesti Anonymous koji djeluju kao anonimna internetska udruga čiji je zadatak razotkriti propagande te političke ratove koji se vode na internetu. Možda i najpoznatiji slučaj je onaj iz 2006. godine, a riječ je o Julianu Asangeu, utemeljitelju stranice WikiLeaks koja je objavila bazu podataka s više od 1,2 milijuna državnih dokumenata. Utemeljitelj stranice započeo je u Australiji, nakon čega se server prebacuje u Švedsku s obzirom da tamo zakon štiti autora stranice te on može ostati anonimane. Michael Ray (2017.) u članku iznosi da je WikiLeaks „svoj prvi snop informacija preuzeo s ToRa (The Onion Router), enkriptirane mreže dizajnirane za anonimni prijenos podataka. Nedugo nakon promjene servera prikupio je više od milijun dokumenata tajnih državnih službi.”

U ovom radu valja spomenuti i nešto kasniji poznati slučaj vezan uz Rusiju. Kako navodi Dokman, Kuzelj i Malnar, Eric Westervelt u svom članku iz 2017. godine naslova „Kako Rusija zloupotrebljava društvene mreže uz pomoć računalnih robota” upozorava javnost na informacijski rat koji provodi Rusija. Naime, Rusija je dizajnirala robote, takozvane „botove” koji šire lažne vijesti i razne propagandne sadržaje na društvenim mrežama, ovisno o potrebama države. Drugim riječima, Westervelt situaciju s robotima povezuje s postizanjem vanjskopolitičkih ciljeva (Dokman, Kuzelj i Malnar 2018: 140). Pomerantsev i Weiss (2014) navode kako je informacijski razvoj društvenih mreža omogućio državama globalno širenje, plasiranje (u ovom slučaju)

proruskih narativa služeći kao glavno sredstvo utjecaja na skupinu ljudi izvan granica Rusije (Dokman, Kuzelj i Malnar 2018: 180). Dokman također navodi kako je riječ o tzv. strategiji refleksivne kontrole koja je zaživjela za vrijeme hladnog rata, a pri definiranju strategije koristi se definicijom Thomasa (2004: 237) koja kaže da se radi o „načinu diseminiranja pažljivo odabranih informacija prema protivniku kako bi ga se nagnalo na dobrovoljno izvršavanje unaprijed zacrtanih odluka napadača."

Prema Dokmanu, Kuzelj i Malnar (2018: 140) jedan od najvećih ekscesa ruske informacijske aktivnosti bio je usmjeren prema Ukrajini, a oni su putem društvenih mreža širili dezinformacije o fašistima i nacistima koji navodno kontroliraju novu ukrajinsku vladu (Davis 2017). Ruske informacijske aktivnosti time su htjele stvoriti pomutnju i pobuditi nacionalno nepovjerenje prema državnim vlastima u Ukrajini. One su, što čak potvrđuje i NATO u svojem izvještaju, bile primarno oružje ruskih operacija. Nato piše u svom izvještaju Analysis of Russia's Information Campaign against Ukraine iz 2014. godine kako je sinkronizirano korištenje informacijskih kampanja i vojnih snaga predstavilo novo razdoblje modernog ratovanja u okviru kojeg se oružani sukob s tla preselio u virtualni prostor (Dokman, Kuzelj i Malnar 2018.: 140).

4. KODOVI I ALGORITMI

Kodovi su nastali još u srednjem vijeku. Predstavljaju skupinu šifriranih brojeva, slova ili simbola koji zamjenjuju riječi, rečenice, dijelove rečenica, slova i brojeve. Najčešće tvore određeni oblik abecede, odnosno rječnika koji služi lakšem raspoznavanju kodnih rečenica i interpretaciji napisanih poruka ili naredbi. Služili su najčešće u svrhu prijenosa tajnih operacijskih poruka. Kasnije, pojavom interneta i binarnoga sustava, dobili su potpuno novo značenje i svrhu pa tako danas računalni programi, kao i internetske stranice, u pozadini svoje izrade prepoznaju kodove putem kojih formiraju gotovu cjelinu prikazanu u rečenicama, sličicama, GIF-ovima i slično. Prema rječniku Merriam Webster kod je sistem principa i pravila, sistem simbola (kao što su brojevi i slova), odabranih riječi ili fraza koji se koriste umjesto druge riječi ili fraze u svrhu komunikacije poruke bez da je značenje izričito navedeno. Kako navodi Hannah Fry u svojoj knjizi „Hello World: Being Human in the Age of Algorithms“ (2018.), iza svake veće inovacije na internetu stoji dobar algoritam. Ista autorica za algoritme kaže da su oni „nevidljivi dijelovi koda koji formiraju glavu i rep mašinerije modernog doba, algoritmi su svijetu dali sve - od naslovnica društvenih mreža do pretraživačkih sustava, satelitske navigacije, glazbene preporuke servisa te su veliki i jednaki dio moderne infrastrukture kao i mostovi, zgrade i tvornice.” (Fry, 2018:n.p.)

Baza podataka je skup informacija, odnosno algoritama, prikupljenih od strane interakcija korisnika koji su pristupili mreži i koji ju koriste. To su najčešće interakcije kao što su sviđanja, komentiranje, dijeljenje sadržaja i pregledavanje hiper linkova pronađenih na društvenim mrežama. Interakcije ostavljene od strane korisnika društvenih mreža ostavljaju trag koji se interpretira kao povratna informacija. Informacijski sustavi prate takve interakcije i kreiraju arhetipe ponašanja korisnika koji se temelje na skupu klikova ostavljenim na društvenim mrežama.

Paul Dourish objašnjava kompleksnost algoritama koju promatra iz više kuteva, a navodi kako različiti jezici, kao i različiti oblici programskih jezika, koriste različite oblike algoritama i svaki od njih funkcionira na specifičnom principu svojevrsnom za njegovu upotrebu. Različiti računalni kodovi, programi, knjižnice informacija, raspored memorijske hijerarhije informacija koriste iste algoritme koji se upotrebljavaju i djeluju na različitim principima. On oblikuje prvobitni kod namijenjen za izradu i prikaz stranice. Oni čitaju podatke iz riznice interakcija, spajaju se na mrežne stranice, provjeravaju ispravnost i moguće poteškoće u interakciji, provjeravaju i šalju povratnu informaciju o dostupnosti memorije na stranici te sve to šalju kao povratnu informaciju koja se

onda čita u obliku koda. (Dourish, 2018:5) Drugim riječima, sve što program radi, a kod kao skup simbola naredi, algoritam specificira i formalizira u signale koji prate praktični i upotrebljivi dio zadanih funkcija. Kod kao takav daje naredbu koju algoritam prati i šalje povratnu informaciju o tome kako se te naredbe koriste od strane vanjskih korisnika. Takve informacije su u svojim počecima najviše koristile tvorcima društvenih mreža. Oni su na temelju povratne informacije algoritma stvarali statističke podatke o tome koliko ljudi koristi pojedinu društvenu mrežu, za što se najviše koriste te što najviše pregledavaju na društvenoj mreži. Kasnije, većom pojavom interakcija na društvenim mrežama te većom količinom sakupljene statistike, baza podataka korisnika postala je „zlatni rudnik“ interneta.

Pri tome, kako je već istaknuto, treba zaštititi informacije koje se dijele na društvenim mrežama upravo iz razloga što se traže osobni podaci, ali i preferencije po pitanju hobija, interesa te prijašnjih iskustava, posjećenih mjesta, prebivališta, boravišta i slično. S druge strane, algoritmi su omogućili kreiranje društvenih mreža koje se čine po mjeri korisnika, iako je ona virtualno stvorena i, možda, nije prikaz realne društvene slike. NATO (2014) ističe kako društvene mreže podrazumijevaju internetske i softverske platforme pomoću kojih se prikupljaju, pohranjuju, dijele, procesuiraju, ili dostavljaju medijski sadržaji, pojedinačno ili generalno, koji mogu utjecati na svjesnost, tj. stvarnost, percepciju i prihvaćanje, odnosno podrazumijevaju one platforme preko kojih se na posredan način, kao sredstvom interakcije, mogu promicati određena ponašanja (prema Mlinac, 2017: 38).

Matematički gledano, po definiciji rječnika Merriam Webster, algoritam je proces ili set pravila koji računalno prati problemske operacije, posebice računalne, navodi Fry (2018:n.p.). Ista autorica zaključuje da je algoritam serija logičkih naredbi koja otkriva kako od početka do kraja izvršiti zadatak. Po ovoj definiciji bilo koja uputa može biti algoritam, pa tako i recepti, upute za sastavljanje računalne stolice i slično. Također, ista autorica zaključuje kako se računalni algoritmi odvijaju na četiri razine.

Prva razina je razina prioriteta, odnosno kreiranja točno određene liste koja pretpostavlja najbolje opcije za pretraživanje riječi koju korisnik traži. Primjer je Google tražilica koja prilikom pretraživanja radi listu najboljih odabira ili Netflix (*streaming* platforma za gledanje filmova i serija) koji daje listu preporuka po željama korisnika. Algoritmi u ovoj situaciji procesuiraju informacije slijedom koji je najrelevantniji za korisnika.

Druga razina predstavlja razinu klasifikacije, odnosno odabira kategorije. Na drugoj razini algoritama najčešće se koriste upravo osobne informacije koje je korisnik sam upisao ili naveo. Primjer je kada nakon završenog fakulteta korisniku izlaze objave o otvorenim radnim mjestima, ili kada, recimo, nakon navršene 30. godine života ženskim korisnicima izlaze reklame o *antibaby* pilulama ili trgovinama koje prodaju dječju odjeću i igračke. To su, također, navodi Fry (2018.: n.p.), algoritmi koji prepoznaju i otklanjaju neprimjeren sadržaj na YouTubeu, kao i algoritmi koji će korisniku označiti fotografije koje su uslikane isključivo na godišnjem odmoru.

Treća razina je razina asocijacija. Najlakše ju je opisati kao algoritam koji pronalazi poveznice koje najviše odgovaraju korisničkim preferencijama temeljenim na njegovim osobnim podacima ili interakcijama koje je prethodno ostavio na internetu ili društvenoj mreži. Amazon pretraživač koristi slične algoritme koji služe prepoznavanju prethodno pretraženih stvari i na temelju njih izbacuje predloške proizvoda koji bi mogli zanimati korisnika.

Četvrta, ujedno i zadnja razina po Fry (2018: n.p.), jest filtracija i odvajanje potrebnog od nepotrebnog. Algoritmi upravljaju velikom količinom informacija koje je potrebno filtrirati i izdvojiti ono najbitnije. Ponekad se koriste, kako navodi autorica, razne metode kao što su algoritmi prepoznavanja govora koje koriste Siri, Alexa i Cortana (umjetnom inteligencijom napravljen osobni asistent u svrhu pomaganja korisniku pri korištenju informatičke opreme; mobiteli, kućanski aparati i slično). Oni odvajaju glas korisnika od pozadinske buke i na temelju njega izvlače ključne riječi koje se kasnije prikazuju na korisničkoj naslovnici. Također, Facebook i Twitter filteri koriste se objavama koje su označene kao „sviđa mi se" (*like*) i tako kreiraju naslovnicu koja odgovara preferencijama korisnika.

Korištenje algoritama postala je računalna svakodnevica. Također, korisnici društvenih mreža postaju ovisni o algoritmima i pretpostavkama izbora sadržaja na koje ih internet navodi. To se događa, primjerice, kada korisnik odluči pretražiti nešto na Google tražilici i pri tome se većinom oslanja na prvu stranicu rezultata tražilice vjerujući sustavu (algoritmu) i njegovom najboljem odabiru pretražene riječi. Oslanjanje na algoritme može biti opasno s obzirom da oni danas, u velikoj mjeri, kreiraju stvarnost građana. Fry (2018.: n.p.) zaključuje da bi se kontrola algoritama trebala odvijati na većoj razini, s obzirom da on prati kod na koji je moguće utjecati i koji postavlja uvjete rada algoritma. Na primjer, pretraživanjem riječi „*math-professor*" i odlaskom na opciju „slike", prikaz ilustracija bio je gotovo pa zapanjujuć. Većina fotografija prikazala je bijelog muškarca ispred ploče za pisanje, time odbacujući realnost crnog muškarca, ili bijele, odnosno crne

žene kao profesorice matematike. Realna je slika nešto drukčija, iako statistički bijeli muškarci prevladavaju u spomenutom zanimanju. Internetski prostor, koji se služi prikazom realnosti, može tu realnost suptilno i mijenjati. Stvar je klasifikacije koja se događa, a kao posljedicu može imati negativan utjecaj na korisnike interneta i društvenih mreža. (Fry, 2018: n.p.)

5. „FILTER MJEHURIĆI“ KAO POSLJEDICA KORIŠTENJA DRUŠTVENIH MREŽA

Kodovi i algoritmi su temelji *web* stranica pa tako i društvenih mreža. Kod daje osnovni prikaz društvene mreže te njezinih glavnih odrednica kao što su položaj teksta, font teksta, prikaz i dimenzije slike, raspored elemenata stranice te drugo. Algoritam predstavlja „srce“ stranice, pokrećući kod i koristeći sve njegove elemente kako bi stranica interakcijski funkcionirala. Prikuplja informacije, analizira ih i stavlja u bazu podataka koja se kasnije koristi kao glavni alat prilikom kreiranja budućeg sadržaja za korisnika.

Korištenje društvenih mreža u mnogo čemu se čini korisnim. Algoritmi u kontekstu kreacije sadržaja po mjeri korisnika zvuči kao idealizirana slika batlera kojeg su svi uvijek htjeli imati u kućanstvu. Međutim, algoritmi nekada funkcioniraju i na princip ponovljenih i lakih sadržaja koji su drugi korisnici najviše pregledavali. Lak sadržaj u današnjem svijetu medija jest onaj sadržaj koji sadrži „žuti“ tisak, trač ili bilo koji oblik tzv. *clickbaita*. *Clickbait* je naslov koji stoji iznad hiperlinka, nekoga teksta ili drugoga medijskog sadržaja te navodi na određenu informaciju koja se potom ispostavi kao nešto drugo. Po definiciji Merriam Webster rječnika *clickbait* predstavlja nešto (poput naslova) namijenjeno čitatelju da klikne na vezu, posebice kada veza dovodi do sadržaja sumnjive vrijednosti ili interesa. Cilj *clickbaita* je da korisnik „klikne“ ne članak time donoseći zaradu određenom internetskom portalu ili internetskoj stranici. Ovakva je praksa učestala u današnje vrijeme te je sve više onih koji ju koriste te je sve više i onih korisnika koji prepoznaju ovakvu praksu na društvenim mrežama.

Internet se drastično promijenio od svojega početka. Od prve namjene koja je trebala služiti lakšoj organizaciji dokumenata koji bi se koristili računalnom mrežom, postao je glavno mjesto proizvodnje, distribucije te dostupnosti informacija. Raznovrsnost informacija i mogućnost izbora više izvora informacija u svijetu koji je doživio globalizaciju i masovno širenje čini se kao prednost. Međutim, mnogi korisnici odlučuju konzumirati isključivo sadržaj i informacije koje odgovaraju njihovim stavovima. Kritičari poput Sunsteina (2009.), navode Flaxman, Goel i Rao (2016: 4), predvidjeli su rast „komora jeke” (engl. *echo chambers*) gdje su korisnici „pogođeni“ sadržajem koji se isključivo prilagođava njihovim stajalištima. Također, internetske tražilice, medijski pokrovitelji i društvene mreže dodatno personaliziraju sadržaj koji se pojavljuje na korisničkom sučelju prema unaprijed programiranim algoritmima koji kreiraju „filter mjehuriće” te posljedično

vode prema ideološkom odvajanju. „Pojava filter mjehurića ne utječe samo na to kako dolazimo do vijesti, već i na način na koji mislimo.” (Pariser, 2010.)

Pojavu, koncept i način rada „filter mjehurića“ objasnio je Eli Pariser u svojoj poznatoj knjizi „Filter Bubble: What the Internet is Hiding From You“, objavljenoj 2010. godine. U njoj je objasnio na koji se način informacije koriste i filtriraju te kako korisnici upadaju u rutinu informacija gdje ostaju zarobljene u bespućima društvenih mreža pregledavajući jedan te isti sadržaj. Prema Pariseru (2010: 4), sve je počelo 4. prosinca 2009. godine kada je Google objavio izmjene pravila privatnosti na svom korporativnom blogu. Blog je objavljen gotovo pa tajno, ali nije ostao neprimijećen. „Tog jutra Google je počeo koristiti 57 signala - sve otkuda se logirate do koji pretraživač koristite te koja je vaša povijest pretraživanja - kako bi pokušali odgonetnuti tko ste vi i kakve stranice bi vam se sviđale. Čak i ako ste odjavljeni, on prilagođava svoje rezultate i pokazuje vam stranice koje algoritam pretpostavlja da vam se sviđaju” Pariser (2010.: 4).

Pariser (2010) ističe kako se personifikacija sadržaja odvija u obliku pogodbe. Za uslugu filtracije sadržaja i personifikacije naslovnice korisnik velikim tvrtkama daje zauzvrat veliku količinu informacija o svojem svakidašnjem životu. Takve tvrtke imaju sve veće količine korisničkih podataka i sve bolje algoritme koji taj sadržaj filtriraju i primjenjuju svakog dana. Problem je u tome što povjerenje koje korisnik daje tvrtkama za prikupljanje podataka jest većinom povjerenje s kojim korisnik nije upoznat te se većina prikupljanja događa u pozadini bez da korisnik zna što se stvarno događa s informacijama koje ostavlja na društvenim mrežama. (Pariser, 2018.: 14). Potrebu za prepoznavanjem interesa korisnika uočili su utemeljitelji najveće svjetske internetske tražilice – Googlea. Ono što karakterizira kvalitetnu internetsku tražilicu jest prepoznavanje što korisnik točno traži i koja mu informacija prilikom pretraživanja točno treba. Google nije htio dati korisniku bezbroj stranica na kojem može pronaći odgovor već jednu na kojoj će biti najrelevantnije informacije koje korisniku trebaju. Ono što se pokazalo problemom jesu pojmovi koji imaju isti oblik, a suprotno ili drugačije značenje, u hrvatskom jeziku poznatiji kao homonimi. Ako korisnik pretraži riječ „pantera”, tražilica ne prepoznaje misli li se na panteru životinju ili Panteru sportski tim. Kako bi tražilica odgovorila na takva pitanja ona mora poznavati korisnika (Pariser, 2018: 22).

Glavna je razlika između Google tražilice i bilo koje druge društvene mreže u količini informacija i načinu distribucije informacija. Google većinom koristi pretražene riječi, klikove na web mjesta te informacije poput, primjerice, kakvu poštu korisnik prima te na koje stranice se pretplaćuje.

„Puno brige se stvara oko matematike kodova i algoritama koji vrlo dobro rezoniraju što se korisniku sviđa te tako analiziraju njegovu osobnost. Izgleda da smo dopustili algoritmima da nam kažu što misliti i raditi. Vijesti koje primamo su iskidane i prezentirane na način koji je dokazano korisnicima najuvjerljiviji." (Sumpter, 2018: n.p.) Društvene mreže pak koriste informacije koje korisnik pušta u opticaj i koje nesmetano cirkuliraju unutar društvenih mreža. Osim što koristi podatke kao što su statusi, fotografije i lokacije, društvene mreže također vide što korisnik označuje sa „sviđa mi se", što najčešće komentira, kakve hiperlinkove otvara i s kojim se informacijama najčešće služi prilikom korištenja društvene mreže. Pariser ovo potvrđuje izjavom Marka Zuckerberga, jednoga od tvoraca društvene mreže Facebook, iz 2007. godine koji kaže kako „Facebook objavljuje više vijesti u jednom danu putem svojih 19 milijuna korisnika već bilo koji medij u povijesti." (2018.: 25) Prema Internet Live Statsu Facebook broji 2,6 milijardi korisnika dok se broj svake sekunde povećava (datum pristupa 5.8.2020.).

„Filter mjehurići", navodi Pariser, nevidljivo transformiraju svijet koji korisnik doživljava putem društvenih mreža tako što kontroliraju što će od informacija vidjeti, a što ne. Igraju se s mentalnim procesima i izvanjskom realnošću. Pariser također tvrdi da, ako korisnik želi znati kako svijet stvarno izgleda, mora razumjeti kako filteri oblikuju i formiraju svijet oko njega. (2018.: 48.). Čovjekova najveća prednost je mehanizam uspostavljanja kognitivnoga balansa. Bez da posebno razmišlja o tome, čovjek gradi most između znanja iz svoje prošlosti i povezuje ga sa znanjem i informacijama iz sadašnjosti. Upravo ta funkcija, tvrdi Pariser, omogućava čovjeku preživljavanje u svijetu i okruženju koji se tako brzo i često mijenja. (2018: 49). Pariser (2018.: 49) također ističe da na dva važna načina personalizirani filteri mogu poremetiti navedenu kognitivnu funkciju zaslužnu za balans i uspostavljanje veze između prošloga znanja i sadašnjih informacija. Prvi način, „filter mjehurići", korisnika okružuju s idejama s kojima je on već prethodno upoznat (te se s njima i složio) i tako potiče jednoumlje te podiže samopouzdanje unutar mentalnih okvira korisnika. Drugi je način, ako ne i važniji, što iz okruženja korisnika miče sadržaj koji bi ga naveo na propitivanje i daljnje učenje.

„Filter mjehurići" ne moraju nužno biti negativni jer, prije svega, izbacuju informaciju koja je najrelevantnija za korisnika što je često vrlo korisno. Ako korisnik, primjerice, odluči pretražiti restorane u svojoj blizini, dobro je što će mu algoritam izbaciti kafiće i bistroe. Međutim, ako se tražilici postavi pojam koji zahtijeva sagledavanje tematike iz više kuteva, „filter mjehurići" mogu biti opasni za korisnika davajući mu rezultate koji odgovaraju njegovim, već prethodno pretraženim, pojmovima (Pariser, 2018.: 55). Gledano s te strane, filtriranje i personaliziranje

sadržaja kojega korisnik pretražuje ili vidi na naslovnicama društvenih mreža uvelike može promijeniti njegovu sudbinu ili tijek događanja. Ovo potvrđuje i Pariser, navodeći da „filter mjehurići" ne reflektiraju samo naš identitet, već i ilustriraju izbor koji imamo. Studenti koji idu na privatne fakultete često vide targetirane oglase studentskih poslova za koje studenti na državnim fakultetima nisu ni svjesni da postoje. Personalizirani sadržaj profesionalnih znanstvenika izbacuje članke kojih amateri nisu ni svjesni. Ilustriranjem mogućnosti i blokiranjem onih mogućnosti koje algoritam ne prepoznaje za korisnika, „filter mjehurići" igraju veliku ulogu prilikom odabira sadržaja za korisnika te, u konačnici, formira tko korisnik postaje." (2018: 63). Svaka stranica na internetu koristi sebi specifične algoritme koji, na jedan ili drugi način, prikupljaju informacije i prema njima kreiraju realnost koju korisnik vidi na internetu ili društvenim mrežama. Google se, prigodom kreiranja slike o korisniku, koristi informacijama, poput što je korisnik pretraživao i na što je najčešće klikao. Google pretpostavlja hobije, interese i karakter korisnika kako bi mu pružio što relevantniju informaciju. Facebook, s druge strane, također gleda što je korisnik kliknuo. Međutim, više od toga, njega zanima što korisnik dijeli na svojem profilu te s kime najviše ostvaruje interakciju. Ova dva pristupa čine se sličnima, ali se također i u mnogočemu razlikuju. „Postoji velika razlika između „ono si što klikaš" i „ono si što dijeliš", navodi Pariser (2018.: 64).

Pariser također piše i o marketinškim tvrtkama kojima nikad nije bilo lakše doći do korisnika diljem svijeta. Osim što imaju mogućnost proširivati tržište te time zarađivati više, danas je moguće i educirati i informirati o svojim proizvodima putem više medija te tako proširivati interes za proizvod bez da korisnik nužno ima potrebu za proizvodom. (Pariser, 2018.: 109) „Algoritmi kreiraju okvir koji prepoznaje inventar korisnika - što korisnik posjeduje, gdje to ostavlja i što radi s njim. Takav fenomen se naziva ambijentalna inteligencija." (Pariser, 2018.: 109). Personalizacija sadržaja je do sada već dobro poznati pojam svakom korisniku koji učestalo koristi internet. Osim što se oglasi prilagođavaju njegovim interesima, personalizirani edukativni i informativni sadržaj također pronalazi svoje mjesto u intelektualnom prostoru svakoga pojedinca na internetu. Pariser iznosi primjer gdje skupina znanstvenika raspravlja o mogućnosti personaliziranih web stranica za svakoga pojedinačnog korisnika. Svaki korisnik drukčije reagira na određeni proizvod, ali oni također različito reagiraju i na dizajn stranice, boje te na opise proizvoda. U svojoj knjizi Pariser navodi primjer tima stručnjaka pod vodstvom Johna Hausera koji su osmislili osnovnu algoritamsku tehniku koju nazivaju „web site oblikovanje" (*website morphing*). Ova tehnika analizira klikove korisnika kako bi otkrila koje ga informacije zanimaju te koji je stil prezentacije najefikasniji u svrhu kreiranja sučelja koje odgovara na individualne kognitivne stilove korisnika. Hauser također navodi da ovakav pristup prilikom internetske kupovine povećava namjeru kupnje

korisnika za 21%. (prema Pariser, 2018.: 113.) Ovo potvrđuje i Fry (2018.: n.p.) koja ističe kako je jako mala razlika u načinu poslovanja Googlea, Facebooka, Instagrama i Twittera. „Giganti interneta poput Facebooka, Instagrama i Twittera ne zarađuju kreiranjem profila na društvenim mrežama. Glavna postavka njihovog poslovnog modela krije se u mikro targetiranju. To su gigantski motori koji služe kao dostavljači reklama, zarađuju tako što milioni korisnika svaki dan aktivno klikaju na njihovim stranicama, čitaju sponzorirane objave, gledaju sponzorirana videa, pregledavaju sponzorirane slike. Na kojem god kutu interneta korisnik bio, makar i u pozadini, algoritmi razmjenjuju informacije koje on ostavlja i za koje ne zna da su predmet razmjene.” (Fry, 2018.: n.p)

6. „KOMORE JEKE“ KAO POSLJEDICA FILTRIRANJA INFORMACIJA

Dakle, kao što je već istaknuto, filtriranje informacija koje je potpomognuto algoritmima služi tome da korisnici dobiju što relevantniji sadržaj na osnovu svojih interesa, prijašnjih „lajkova“, komentiranja i dijeljenoga sadržaja. „Filter mjehurići“ omogućili su društvenim mrežama kreiranje specificiranog sadržaja koji se čini po mjeri svakog korisnika. Oni ne samo da brinu o sadržaju koji je korisnik prije toga označio kao njemu zanimljiv, već brinu o budućem sadržaju i unaprijed razmišljaju o interesu korisnika.

Današnja logika interneta zasniva se na činjenici da je svaki klik bitan neovisno o sadržaju te da svakim klikom korisnik ostavlja informaciju i tvori bazu podataka od koje pojedine tvrtke zarađuju, a algoritmi prikupljaju statistiku kako bi upoznali korisnika i prepoznali njegov interes prema daljnjim objavama. Logično je da se korisniku izbacuje češće što raznovrsniji sadržaj kako bi se njegovi interesi produbljivali i time njegovi klikovi bili što učestaliji i raznovrsniji. Baza podataka tako postaje veća kao i njihova tržišna vrijednost te korisnik dobije osjećaj da ga njegova tražilica ili društvena mreža u potpunosti poznaju i da im može vjerovati.

Iako pojam „komore jeke” nije u potpunosti istražen te se još uvijek proširuje njegova definicija i uporaba na internetu, u ovom radu pokušava se odrediti i objasniti kroz kontekst sadržaja koji se korisniku pojavljuje na naslovnicama društvenih mreža. Kathleen Hall Jamieson i Joseph N. Capella u svojoj knjizi „Rush Limbaugh and the Conservative Media Establishment, Echo Chamber“ iz 2008. godine pojam „komore jeke” objašnjavaju kroz politički primjer američke političke ljevice i desnice te medijske pažnje koja je usmjerena na čitateljstvo. „Komore jeke” su u velikoj mjeri utjecale te još uvijek utječu na političke stranke, publiku koja ih prati te na mišljenja koja se kreiraju i cirkuliraju društvenim mrežama, a tiču se pojedinih stranki. No, u ovom radu fokus je na tehničkim aspektima pojma „komore jeke”, s obzirom da politički i medijski aspekt izlaze iz njegova okvira. Isti autori „komoru jeke” objašnjavaju kroz metafore. Jamieson i Capella „komore jeke” definiraju kroz poruke koje se mogu pronaći na društvenim mrežama (uključujući međusobni podijeljeni sadržaj ili javno komentirani sadržaj) koje se međusobnim ponavljanjem pojačavaju te time odjekuju na internetu tvoreći konzervativnu sredinu (2008.:76). Fry (2018.:n.p.) pak objašnjava kako algoritmi funkcioniraju u domeni „komora jeke” kroz slučaj agencije Cambridge Analytica. Posrijedi je britanska agencija, koja je 2013. godine otvorena pod vodstvom Alexandra Nixa, a koja se bavila prikupljanjem informacija koje korisnici ostave na internetu te

kreiranjem baze podataka u svrhu stvaranja algoritama koji daju najbolje rezultate za potrebe klijenata koji su angažirali za takvu vrstu usluga. Cambridge Analytica je, između ostaloga, pomogla personalizirati reklame i poruke za vrijeme kampanje uoči predsjedničkih izbora 2016. godine u Sjedinjenim Američkim Državama, također pomoću algoritama te informacija prikupljenih od samih korisnika.. Godinu dana prije osnivanja spomenute tvrtke skupina znanstvenika sa sveučilišta Cambridge i Stanford počela je tražiti poveznicu između pet razina osobnosti i stranica koje su ljudi označili sa „sviđa mi se" na društvenoj mreži Facebook. Kreirali su upitnik koji se rješavao putem spomenute mreže u svrhu pronalaska poveznice između korisničkoga karaktera i njegove *online* persone. Korisnici koji su odlučili riješiti upitnik su, u neznanju, predali informacije o sebi koje su pomogle znanstvenicima u pronalasku odgovora na njihovo pitanje tko su korisnici te koje su njihove osobine. Pristanak na ispunjavanje upitnika, također je bio i pristanak na dijeljenje podataka koji govore što su korisnici označili kao „sviđa mi se" na svom profilu te su rješavanjem upitnika dali odgovore na pitanje kako korisnici na sebe gledaju u stvarnom životu.

Fry (2018:n.p.) navodi kako su rješenja i rezultati bili zapanjujući. Korisnici kojima se sviđa Salvador Dali, meditacija i TED razgovori su najčešće oni koji su imali visoke rezultate u smjeru otvorenosti prema novim iskustvima. Također, korisnici koji su znakom „sviđa mi se" označili plesanje ili lik Snooki iz serijala Jersey Shore imali su visoke rezultate ekstrovertiranosti. Istraživanje je bilo uspješno, što je navelo tim stručnjaka na izgradnju algoritma koji će pretpostaviti nečiji karakter na temelju njegovih prijašnjih sviđanja. Ista autorica dalje navodi kako je grupa znanstvenika, godinu dana nakon prvoga istraživanja, zaključila da prikupljanjem 300 oznaka „sviđa mi se" s nečijega profila algoritam može pretpostaviti karakter korisnika bolje nego njihov partner (Fry, 2018.:n.p.) Ovakvo istraživanje pomoglo je u personalizaciji reklama, postavljajući drukčije reklame introvertima i ekstrovertima u svrhu približavanja produkta svakom korisniku pojedinačno. Također, ovakva analiza informacija omogućava kreiranje „komora jeke". Algoritam pretpostavlja karakter korisnika te prema njemu stvara naslovnicu koja sadržajno najviše odgovara pretpostavljenim osobinama korisnika.

Cambridge Analytica se, navodi Fry (2018.:n.p.), koristila personaliziranim algoritmima koji su kreirali sadržaj koji je odgovarao njihovom karakteru te ih tako povezivao s ljudima koji afirmiraju već nametnuti narativ algoritma. Ista autorica zaključuje da je spomenuta kompanija otišla korak dalje, tražeći samohrane majke koje imaju visok rezultat povezan s neuroticizmom i strahom od napada, tako da je algoritam izbacivao propagandne poruke vezane uz državu slobodnu prema

korištenju oružja. Mnogi „zviždači“ tvrde da je algoritam samo početna točka, a da se Cambridge Analytica, osim toga, koristila i novinarstvom, pišući članke koji sadržavaju dezinformacije i lažne vijesti (*fake news*) i izbacujući ih ciljnim skupinama kako bi željeni kandidat za predsjedničke izbore (Donald Trump) dobio što više glasova. Fry nadalje navodi kako korisnici često podcjenjuju ciljane marketinške objave (2018.:n.p.). Korisnici često za sebe misle kako nisu podložni manipulaciji te da se njihovo stajalište ne može lako promijeniti. Međutim, istina se nalazi negdje između. Po istoj autorici sadržaj koji se prikazuje na društvenim mrežama uvelike utječe na emocije korisnika. Istraživanje provedeno 2013. godine, a koje opisuje Fry, temelji se na korištenju sadržaja pozitivnoga ili negativnoga predznaka te reakcije korisnika na njega. Nakon prezentacije pozitivnoga sadržaja na korisnikovoj naslovnici rezultat je bio takav da je korisnik nastavio dijeliti i komentirati također pozitivni sadržaj. S druge strane, korisnicima od kojih je bio skriven pozitivni sadržaj i prikazan isključivo negativni, počeli su i sami koristiti ružne riječi te komentirati i dijeliti negativan sadržaj. Zaključak je, navodi Fry, takav da korisnik može misliti kako nije podložan emocionalnoj manipulaciji, ali u većini slučajeva ipak jest.

Velike su prednosti u filtriranju i personaliziranju sadržaja korisnika s obzirom da on u bilo koje vrijeme može doći do gotovo svih informacija dostupnih na internetu. Otvoreno tržište koje je omogućio internet bilo je gotovo pa nezamislivo prije 30 godina. Ljudi su do informacija dolazili posredstvom poznanika, enciklopedija ili knjiga specifičnih za područje koje ih zanima. Danas je informacija nadomak ruke, a oglasi su omogućili širenje interesa korisnika i produbljivanje znanja. Besplatno tehnološko i informacijsko znanje u zamjenu za podatke korisnika, koji se prikupljanju u svrhu ostvarivanja profita i utjecaja na njegovo razmišljanje i razvoj, jest ugovor koji je korisnik sklopio bez da je znao za njega.

Na primjer, korisnik je veliki obožavatelj marke automobila Ford, prati automobilsku industriju te je pretplatnik više profila društvenih mreža koji redovito izbacuju informacije, fotografije i novosti o navedenoj marki automobila. Pretpostavka „komora jeke” jest da takav korisnik komentiranjem i praćenjem isključivo jedne marke daje algoritmu uputu da nije zainteresiran za ništa drugo. Algoritam na temelju jednoznačnih informacija korisniku izbacuje sadržaj povezan isključivo s onim koje je prethodno pregledavao, tako da korisnik nakon nekoga vremena biva okružen informacijama koje već razumije, poznaje i koje podupiru njegovo stajalište. Također, pretpostavka je da će korisnik u takvim situacijama većinom i ostati vjeran isključivo jednoj marki automobila jer prati i komentira temu s drugim korisnicima koji također afirmiraju njegove stavove i podupiru ga u mišljenju kako je Ford jedini pravi auto za njega. Jamieson i Capella navode da se ovakvim

ponašanjem algoritama stvara „zajednički referentni okvir i petlje pozitivnih povratnih informacija" (2010.: 76), što odvaja korisnika od potrebe za promišljanjem, analiziranjem i istraživanjem tržišta. Potvrđivanjem onoga u što korisnik već vjeruje potvrđuje se i karakter korisnika, time ga navodeći da ostane u svojim zonama sigurnosti i prati sadržaj koji potvrđuje njegove unaprijed formirane stavove.

Problem koji se stvara kod ovoga tipa filtracije sadržaja jest stvaranje ideološke separiranosti. Različita su mišljenja oduvijek prisutna u ljudskoj vrsti, s obzirom da su ljudi jedina bića koja imaju sposobnost razmišljanja, zaključivanja i donošenja odluka na temelju prijašnjih iskustava i sadašnjih informacija. Čovjek razmjenjujući iskustva, stavove i misli dolazi u dodir s drugim, ponekad i suprotnim, a tematski sličnim, iskustvima, stavovima i mislima te uči prihvaćati tuđe mišljenje, širiti svoje obzore i pogledati stvari iz više perspektiva. Pojavom „komora jeke" pojavila se velika prijetnja ljudskom razvoju, a to je uspostavljanje ideološkoga centra, odnosno jednoumlja.
.

R. Kelly Garrett (2020) navodi kako fenomen izbjegavanja stajališta koji je suprotno od našega nije toliko označen prirodom čovjeka. „Komore jeke" pomažu isključivo onim strankama ili opcijama koje sebi traže sljedbenike. Dakle, raznim vjerskim i političkim ideologijama čije je stavove i razmišljanja potrebno konstantno podupirati kako bi se njihova zajednica širila. Dakako, „komore jeke" i jesu najvidljivije kod političkih stranaka, pogotovo onih u SAD-u te za vrijeme izbora.

6.1. „Komore jeke“ – medijski efekt i medijska izloženost

Cappella i Jamieson (2010.: 82) zaključuju da je najveći problem „komora jeke” to što korisnik koji čita sadržaj koji isključivo afirmira njegovo mišljenje postaje superioran i isključiv prema drugim stavovima. Korisnici na internetu medijske portale većinom gledaju kroz prizmu objekta koji objašnjava realnost oko njih, dok oni posredstvom medija imaju slobodu čitati tuđe i pisati svoje stavove te tako formirati vlastiti identitet. Kao uzročno-posljedičnu vezu „komora jeke” stoga autori navode dvije stvari: medijsku izloženost i medijski efekt. (2010.: 83) Medij koji se odluči svoj sadržaj objavljivati na internetu postaje izložen te postiže određeni efekt kod korisnika koji čitaju taj isti sadržaj. Također, autori navode da ponekad medijsku izloženost formiraju komentari i mišljenja korisnika, odnosno osobni i društveni identiteti koji se odluče prokomentirati te time stvoriti medijski efekt. (Cappella, Jamieson 2010.:83)

„Osobni identitet predstavlja način na koji se pojedinac odnosi prema kompleksnijim ili agresivnijim temama; razlike osobnog identiteta se također pronalaze u mišljenju svakog pojedinca, stavu i uvjerenjima koja su karakteristična za individualca. Društveni identitet se odnosi na čovjekovu potrebu za identifikacijom s određenom skupinom ljudi - bila ona vjerska, politička ili ideološka skupina.” (Cappella, Jamieson 2010.:84) Medijski efekt može imati negativnu posljedicu koju autori nazivaju spiralnim efektom te je usko povezana s „komorama jeke”. Spiralni efekt stvara začarani krug stavova unutar kojeg korisnik čita i komentira sadržaj koji afirmira njegovo mišljenje. Na neki način, navode autori, korisnik s izravnim doticajem s „komorom jeke” smanjuje potrebu za stalnim preispitivanjem i kreiranjem osobnoga identiteta. Osobni identitet gradi se vremenski linearno s čovjekovim životom. Čovjek kroz starenje pamti i uči iz prošlosti te primjenjuje znanje u sadašnjost, gradeći svoj osobni identitet. Korištenjem samo jednoga izvora medija koji se poklapa sa stajalištima korisnika posljedično ostavlja identitet korisnika apsolutnim jer se njegova osobnost rijetko ili nikad ne nalazi u situaciji da svoje stavove mora preispitati. „Komore jeke” na određen način hipnotiziraju korisnike koji kroz internetske medije potvrđuju stavove temeljnih ljudskih pitanja kao što su humanost i politika te kao posljedicu „komora jeke“ doživljavaju isključivo afirmaciju tih stavova. (Cappella, Jamieson 2010.;84)

7. FRAGMENTACIJA INTERNETA

Izumitelj svjetske mreže, *World Wide Weba,* Tim Berners-Lee ističe: „Internet kakvoga poznajemo nailazi na prijetnje. Neki od njegovih najpoznatijih doseljenika počeli su rezati temeljne principe interneta. Velike društvenomrežne stranice preuzimaju informacije koje su korisnici postavili te ih dijele ostatku interneta bez znanja korisnika. Države – bile one totalitarne ili demokratske – preuzimaju online navike korisnika te tako prijete temeljnim ljudskim pravima. Ako mi, internetski korisnici, dopustimo nastavak takvim i sličnim trendovima bez naše provjere, internet bi mogao biti podijeljen u male fragmentirane otoke“ (prema Pariser, 2010: 118). Filtriranje i personaliziranje sadržaja utječe na korisnikovu percepciju interneta, ali i svijeta oko njega. Algoritmi osim što prikupljaju osnovne informacije o korisnicima, razumiju korisnike, što korisnici vole, što žele ili ne žele. Čak i ako nisu izuzetno točni, dovoljno su jasni da bi bili profitabilni. Kao rezultat algoritamskih radnji došlo je do kontradikcije. Putem interneta korisnici mogu doći do svakakvih informacija, nužno ne vezanih za samo jednu stvar niti samo jedan kut informacije koja ih zanima. Međutim, pojava „filter mjehurića” na svojevrstan je način zakinula korisnike za drukčije informacije, mišljenja i stavove.

Korisnici također osjete velike prednosti koje su došle posredstvom algoritama te filtracije i personaliziranja sadržaja. Pregledavati Netflix pa čak i čitati naslovnicu Facebooka koja zna što korisnika zanima, često se, u njihovim očima, čini kao blagoslov. Također, Google segmentiranjem stranica koje su bitne ili nebitne uvelike olakšava pretraživanje ključnih riječi. Ono što je zabrinjavajuće, navodi Pariser (2013.: 119), jest činjenica da je takva personalizacija većinom nevidljiva za korisnika te posljedično i izvan kontrole korisnika. Internet može pretpostaviti tko je korisnik, ali korisnici ne znaju što internet o njima pretpostavlja i kako interpretira informacije koje mu on ostavi. Tehnologija koja je napravljena kako bi korisnicima pružila veću slobodu, sada tu slobodu svojevrsno oduzima.

Sumpter (2018) također piše o segregaciji korisnika na one koji međusobno dijele iste karakteristike te navodi kako se stereotipi masovno potvrđuju oznakama „sviđa mi se” na profilima što društvenim mrežama omogućava lakše odvajanje korisnika prema unaprijed kreiranim kategorijama. „Kako bi lakše razumio svoje korisnike, Facebook je kreirao kategorije koje je imenovao po skupini algoritama koja ih zajednički obilježava”, Sumpter otkriva i kako korisnik može vidjeti naziv po kojem ga algoritam prepozna „u gornjem desnom kutu potrebno je otići na

opciju „Postavke”. Jednom kada uđete u svoje postavke, odaberite „Oglasi”, nakon toga odaberite opciju „Postavke oglasa” koja se nalazi nešto niže od vrha stranice.” (Sumpter 2018: n.p.)

Trenutne postavke oglasa na Facebooku izgledaju nešto drugačije. Osim što korisnik može vidjeti svoj oglasni profil, također vidi i interese koje algoritam pretpostavlja da su u domeni interesa korisnika. Korisnik može birati hoće li te iste oglase i nastaviti viđati na naslovnici, ili će ih zamijeniti s nekim drugim. Osim onoga što je korisnik do sada označio kao „sviđa mi se” može vidjeti i informacije koje algoritam prikuplja, a nužno ih korisnik nije ostavio putem klika. Riječ o lokaciji, mobilnom uređaju kojeg korisnik koristi, način mreže na koju se spaja (*WiFi* ili mobilna mreža) te softer uređaja (iOS, Android i slično). Facebook je podijelio postavke oglasa na više segmenata, time dopuštajući korisnicima odabir „fragmenta” koji njima najviše paše.

Oglasi temeljeni na podacima koje Facebook prima od partnera omogućavaju korisniku bolje oglase, dok Facebook u postavkama navodi kako se algoritmi služe podatcima koje oglašivači i drugi partneri pružaju o korisničkoj aktivnosti izvan Facebooka.

Oglasi korisničke aktivnosti prema proizvodima Facebookovih tvrtki koje korisnik vidi na drugim mjestima su dokaz međusobne transakcije informacija i raspodjele istih na internet prostoru. Facebook unutar opcije navodi kako algoritam izbacuje oglase Facebook proizvoda izvan Facebooka, na primjer web stranicama, raznim aplikacijama ili drugim uređajima koji se služe njihovim oglašivačkim uslugama. Također, algoritmi se služe podatcima o korisničkoj aktivnosti unutar proizvoda Facebookovih tvrtki kako bi rezultat bio što relevantniji. (preuzeto s osobnog profila stranice Facebook, datum pristupa: 3.9.2020.)

Odvajanje korisnika po karakteristikama i preferencijama koje algoritam pretpostavi dogodilo se u samom početku kreiranja društvenih mreža. Tada je predstavljao alat koji će međusobno povezivati korisnike te spajati ljude s jednog kraja svijeta na drugi. Danas, algoritam ne radi za korisnika nego svoj matematički rad usmjerava na oglase. Algoritam ne razmišlja o tome kako povezati korisnika s drugim korisnikom, već kako ga povezati s uređajem putem kojeg pristupa mreži jer samo na taj način on ostavlja interakciju i pruža algoritmu veću šansu za upoznavanjem i otkrivanjem tko korisnik je. Što više prikupljenih podataka to je više načina koji usmjeravaju korisnika na određenu informaciju, odnosno u određeni fragment interneta na kojem će korisnik ostaviti najviše interakcije i time donijeti veliku zaradu.

Pariser ponovno citira Tim Berners-Leea koji kaže da „mi kreiramo internet. Mi odabiremo koje postavke želimo imati, a koje ne. U nijednom smislu naš odabir nije gotov (niti je umro).” Pariser

nadalje navodi kako je moguće napraviti informacijski sustav koji će korisnicima prezentirati i upoznavati ih s novim idejama te ih time poticati na kreiranje novih načina funkcioniranja. Još uvijek je moguće stvoriti medij koji će korisnicima radije predstavljati sadržaj koji ne znaju, nego onaj koji reflektira već dobro poznate arhetipe ponašanja. Još uvijek je, navodi Pariser, moguće dobiti sustav koji korisnike neće bacati u spiralu afirmirajućih informacija. (Pariser 2013.:120)

8. ZAKLJUČAK

Kada je Tim Burners-Lee osmislio *World Wide Web* vjerojatno nije niti mogao pretpostaviti da će internet tako brzo doživjeti evoluciju koju će biti teško pratiti. Pojava društvenih mreža bila je sociološki fenomen s obzirom da druženje nikad nije bilo pristupačnije, a komunikacija nikada lakša i brža. Informacije koje su dijeljene prilikom prijave na društvenim mrežama, poput imena i prezimena, datuma rođenja, mjesta boravišta i prebivališta neke osobe, bile su u očima korisnika korisne s obzirom da su omogućavale lakši pronalazak prijatelja i obitelji koji su također kreirali svoj profil. Ubrzo, pojavile su se opcije koje su na zabavan način tražile od korisnika informacije o interesima i hobijima. Nedugo nakon toga pojavila se i mogućnost rješavanja različitih zabavnih testova koji su otkrivali razne informacije o korisnicima kao što su „Kakav si karakter?", „Koja si životinja?" te mnoge druge. Iako naizgled tek obični upitnici, kasnije se ispostavilo da su nešto mnogo više od toga.

Kod na internetu predstavlja simbole i skup naredbi koji tvore programski jezik i na temelju njega kreiraju cjelinu koju korisnik vidi kao web stranicu. Algoritam u sferi interneta predstavlja zapisnik koji prati interakcije korisnika i zatim šalje povratnu informaciju programskom jeziku o načinu upotrebe koda koji stvara bazu podataka.

Iza svake pretražene riječi na tražilici, kao i naslovnice na društvenoj mreži, stoji algoritam koji slaže informacije za koje smatra da su najrelevantnije za korisnika. One se odvajaju po preferencijama korisnika koje je prethodno ostavio. Algoritam prati klikove korisnika, oznake, dijeljenja, pretražene riječi te označene rečenice te na temelju toga kreira personalizirani sadržaj koji odgovara korisniku. Određeni algoritmi idu toliko daleko da se koriste mikrofonom te izrečenim riječima od kojih skuplja ključne riječi u svrhu kreiranja savršenog sadržaja (Siri, Cortana i drugi).

Algoritmi kreiraju realnost korisnika na internetu, a posljedično korisnik reflektira tu realnost na stvarni svijet. Osim što se pomoću algoritama nameću razni marketinški proizvodi u svrhu zarade,

jednako tako razne medijske kuće koriste algoritme kako bi plasirale informaciju, izložile ju što većem broju korisnika te time postigli određeni efekt. Kao posljedicu filtriranja algoritma koji se zbog velike količine istoga ili sličnoga sadržaja počeo ponavljati na različitim stranicama i u istom kontekstu, stvorili su se „filter mjehurići". Pojam koji se često spominje, a također je nastao na temelju proučavanja algoritama i društvenih mreža, jest *echo chamber* („komore jeke"). Drugim riječima, kao posljedica prikupljanja informacija na svakodnevnoj razini (onoga što korisnik najviše označava kao „sviđa mi se", što komentira i dijeli s drugima i drugo), dogodio se kontraefekt u filtraciji i rješenjima koje algoritam pronalazi.

Korisnik koji želi odgovorno koristiti internet i pomoću njega se intelektualno i društveno razvijati mora biti upoznat s pojmom algoritama te s gore navedenim pojmovima. U suprotnom, jako je lako upasti u spiralu informacija koje afirmiraju jedno stajalište te korisnika odvajaju od najveće prednosti interneta, a to je široki odabir informacija te mogućnost proučavanja pojedine teme iz više smjerova. Premda filtracija ponekad može navesti na krivi trag, u većini slučajeva ona je poprilično korisna za korisnika i omogućava mu uvid u informacije koje bi, možda, pretražujući samostalno, izostavio.

9. LITERATURA

Autorske knjige:

1. Erickson J. (2018) *Algorithms, Creative Commons Attribution 4.0 International Licence*. URL: http://jeffe.cs.illnois.edu/teaching/algorithms (datum pristupa: 17. 8. 2020.)
2. Ferguson, R. (2004) *The Media in Question*. London: Arnold
3. Fry, H. (2018) *Hello World: Being Human in the Age of Algorithms*. W.W. Norton&Company, New York, London
4. Jamiseon K.H., Capella J.N., (2010) *Echo Chamber: Rush Limbaugh and the Conservative Media Establishment*. Oxford University Press, New York
5. Miller M. (2003) *Apsolutna zaštita privatnosti PC-ja i privatnosti*. prev. D. Ivanišević, B. Zec, D. Marković, Čačak: Kompjuter biblioteka
6. Pariser, E. (2013) *The Filter Bubble: What the Internet Is Hiding from You*. The Penguin Press, New York
7. Pomerantsev P., Weiss M. (2014) *The Menace of Unreality: How the Kremlin Weaponizes Information, Culture, and Money*. New York: The Institute of Modern Russia
8. Sumpter D. (2018) *Outnumbered: From Facebook and Google to fake news and filter-bubbles - the algorithms that control our lives*. London, Oxford, New York, New Delhi, Sydney: Bloomsbury SIGMA

Zbornik radova:

1. Zgrabljić Rotar, N., Josić. Lj. (2016) *Biblioteka Informacijska tehnologija i medij (knjiga 1): Novi mediji digitalnog doba*. Sveučilište u Zagrebu, Hrvatski studiji

Rad u časopisu:

1. Boyd D.M., Ellison N.B. (2008) Social Network Sites: Definition, History, and Scholarship. *Journal of Computer Mediated Communication*, Vol. 13, str. 210-230

2. Brautović M. (2007) Zaštita privatnosti kod hrvatskih online medija. *Medijska istraživanja*, Vol. 13 (1), str. 51-67
3. Dokman T., Kuzelj M., Malnar D. (2018) Društvene mreže u ulozi modernog oružja. *Polemos: časopis za interdisciplinarna istraživanja rata i mira*, Vol. 21, no. 41, str. 133-150
4. Flaxman S.R., Goel S., M.Rao J.. (2016) Filter Bubbles, Echo Chambers, and Online News Consumption, Public Opinion Quarterly, Vol. 80., 298-320
5. Grbavac J., Grbavac V. (2014) Pojava društvenih mreža kao globalnog komunikacijskog fenomena. *Media, culture and public relations,* Vol. 5(2), str. 206-219
6. Šuljug R., Relja R., (2009) Novi oblici rada u umreženom društvu. *Informatol*. Vol. 43 (2) str. 143-149

Članak na mrežnoj stranici:

1. Demeterffy Lančić R. (2010) Novi mediji i odnosi s javnošću. *Medijske studije*, str. 157-169, URL: https://hrcak.srce.hr/76708 (datum pristupa 27. 8. 2020.)
2. Dourish P. (2016) Algorithms and their others: Algorithmic culture in context. *Big Data&Society*, str. 1-11 URL: https://journals.sagepub.com/doi/10.1177/2053951716665128 (datum pristupa: 22. 8. 2020.)
3. Ferenčić M. (2012) Marketinška komunikacija u digitalnom svijetu. *Praktični menadžment: stručni časopis za teoriju i praksu menadžmenta,* (str. 42-46), URL: https://hrcak.srce.hr/96980 (datum pristupa: 22. 8. 2020.)
4. Milan, S. (2015) When Algorithms Shape Collective Action: Social Media and the Dynamics of Cloud Protesting. *Social Media Public Space* (str. 1-10) URL: https://journals.sagepub.com/doi/full/10.1177/2056305115622481 (datum pristupa: 27. 8. 2020.)
5. Mlinac N., (2016), Političke i sigurnosne dimenzije korištenja društvenih mreža u suvremenom informacijskom prostoru. *Izvorni znanstveni članak* (str. 31-44) URL: https://hrcak.srce.hr/185160 (datum pristupa: 25. 8. 2020.)
6. Ray M. (2017) WikiLeaks media organization and Web site, URL: https://www.britannica.com/topic/WikiLeaks (datum pristupa: 25 .8 .2020.)