
MEDIJI

Izvorni znanstveni članak

UDK 004.738.5:316.4

(1-12)

Primljeno: 10. veljače 2012.

*Mato Brautović**

Utvrđivanje utjecaja internetskih aktivista: Upotreba Twittera u prosvjedima protiv hrvatske vlade

Sažetak

Promoviranje novih ideja u društvenom sustavu usko je vezano uz utjecajne pojedince. Online društvene mreže predstavljaju idealne sustave za prikupljanje empirijskih podataka i analizu problematike uloge pojedinca. U ovom radu prikazano je osam mjera utjecaja na Twitteru: broj followers, broj friends, broj tweets, broj prosljeđenih tuđih poruka (RT), broj poruka korisnika koje su prosljedili drugi korisnici (RT), koliko je puta spomenut korisnik (@), koliko je puta korisnik spomenuo druge korisnike (@) i broj objavljenih poruka o određenoj temi. Utvrđeno je kako postoje dvije vrste utjecajnih korisnika: utjecajni korisnici Twittera opće populacije i tematski ograničene populacije. Nadalje, utvrđeno je kako će, da bi ostvarili utjecaj, Twitter korisnici biti prijatelji i followers te objavljevati veliki broj tweets. Također će prosljeđivati poruke (RT) i diskutirati te komunicirati (@) s drugim korisnicima. Ovisno kojoj skupini korisnika pripadaju, Twitter korisnici će koristiti različite aktivnosti za ostvarivanje utjecaja, kao što je utvrđeno ovim istraživanjem.

Ključne riječi: utjecaj, Twitter, antivladini prosvjedi, Hrvatska, online aktivizam

* Autor je izvanredni profesor Sveučilišta u Dubrovniku, e-mail: mbraut@unidu.hr

MEDIA

Original scientific paper

UDK 004.738.5:316.4

(1-12)

Received: February 10th, 2012

*Mato Brautović**

Determining the impact of the Internet activists: using Twitter in protests against Croatian government

Abstract

The promotion of new ideas in a social system is tightly related to certain influential people. Online social networks are the ideal systems for gathering empirical data and the analysis of the issue of the role of an individual. The current paper explores eight Twitter influence factors: number of followers, friends, tweets, referrals from other people's messages (RT), user messages forwarded by other users (RT), times a user was mentioned (@), times a user mentioned other users (@) and posted messages on a particular topic. It has been established that there are two types of influential users: influential Twitter users of the general population and of thematically limited population. Furthermore, it has been established that, in order to gain influence Twitter users are willing to become friends and followers and to post large number of tweets. They will also forward messages (RT) and discuss and communicate (@) with other users. Depending on which group the users belong to, Twitter users will use various activities to achieve impact, as defined in this study.

Key words: Impact, Twitter, anti-government protests, Croatia, online activism

* The author has a PhD and he is an associate professor at University of Dubrovnik, Hrvatska, e-mail: mbraut@unidu.hr

Uvod

Utjecaj ima značajnu ulogu na to kako, zašto i kojim tempom se nove ideje (inovacije) šire u društvenom sistemu. Postojeće teorije, poput difuzije inovacija (Filder, 2004), upućuju na mali broj utjecajnih pojedinaca koji imaju odlučujuću ulogu u širenju inovacija. Međutim, iz novijih istraživanja vidljivo je kako nisu bitni samo utjecaji pojedinaca, već i spremnost zajednice da prihvati inovaciju (Watts i Dodds, 2007). Ipak, ovo istraživanje će biti temeljeno na utjecaju pojedinaca, odnosno njihovom ponašanju.

Online društvene mreže predstavljaju idealne platforme za prikupljanje empirijskih podataka za istraživanje ove problematike. Nadalje, istraživanje utjecaja omogućuje nam bolje razumijevanje načina kako se inovacije prihvaćaju. Upravo zbog toga kao predmet istraživanja ovog rada uzet je Twitter, odnosno njegova upotreba u organizaciji i komunikaciji aktivističkog djelovanja. Pored toga, Twitter je idealan ekološki sistem kroz koji možemo lako razumjeti odnose među korisnicima i njihovog okruženja na internetu (Levitt, 2009:4).

Twitter predstavlja online društvenu mrežu i mikroblogging platformu, posredstvom kojeg korisnici mogu otvarati profile, uspostavljati prijateljstva i followers te objavljivati kratke postove (tweets) od 140 slovnih znakova. Za razliku od Facebooka, Twitter komunikacija je otvorena za sve internetske korisnike.

Kako bi se olakšalo pretraživanje i pronalaženje tematskih postova, ustalila se upotreba hashtagova, odnosno ključnih riječi koje se dodaju svakom postu. Hashtag se sastoji od ključne riječi koja najbolje opisuje temu i prefiksa #. Pearanalytics (2009) je utvrdio kako sadržajno 44.55% poruka čini pointless babble, 37.55% konverzaciju, 8.7% pass along value, dok je self promotion 5.85% sadržaja.

Levitt et al.(2009:5) definira utjecaj na Twitteru kao potencijal za akciju korisnika da inicira daljnju akciju drugog korisnika. U tom smislu, u Twitter okruženju, korisnik može poduzeti aktivnosti uspostavljanja prijateljstava i followera te objave tweets. „Interpersonalne“ aktivnosti koje korisnik može poduzeti na Twitteru (Cha et. al, 2010: 12) radi ostvarenja utjecaja su:

1. Korisnik može „pratiti“ aktivnosti drugih korisnika (friends)
2. Korisnik može biti „praćen“ od drugih korisnika (followers)

3. Korisnik može objavljivati informacije – postove namijenjene drugima (followers)
4. Korisnik može prosljeđivati tuđe informacije drugima (Retweeting ili RT)
5. Korisnik može odgovarati ili komentirati postove drugih (mentions ili @)

Kod „interpersonalne aktivnosti“ prosljeđivanja postova drugih (RT) postoje dvije vrste korisnika: korisnik koji prosljeđuje poruke i korisnik čija je poruka prosljeđena. Također, kod odgovaranja ili komentiranja (@) postoje dvije vrste korisnika: korisnik koji spominje druge i korisnik koji je spomenut u postu drugog korisnika.

Kako je uzorak dobiven filtriranjem samo onih korisnika koji su objavljivali na temu prosvjeda (#prosvjed), za potrebe istraživanja u obzir će biti uzet i broj postova i broj prijatelja, iako to nije bio slučaj kod Cha et al (2010). Oni su utvrdili da su ti pokazatelji bili značajni samo za utvrđivanje robota i spamera kao najutjecajnijih članova zajednice, što ovdje neće biti slučaj s obzirom da nije riječ o općoj populaciji i specifičnoj temi. Nadalje, praćenje od strane drugih korisnika pokazatelj je popularnosti korisnika, prosljeđivanje poruka je pokazatelj vrijednosti sadržaja, a odgovaranje predstavlja vrijednost korisnika (Cha et. al, 2010: 11). Stoga će ovo istraživanje biti temeljeno na slijedećim elementima koji određuju utjecaj pojedinaca na Twitter:

1. Broj followers
2. Broj friends
3. Broj Tweets (od početka djelovanja)
4. Broj prosljeđenih tuđih poruka (RT)
5. Broj poruka korisnika koje su prosljedili drugi korisnici (RT)
6. Broj spomena korisnika (@)
7. Broj puta koji je korisnik spomenuo druge korisnike (@)
8. Broj poruka objavljenih o određenoj temi

Aktivisti koji su organizirali prosvjede protiv hrvatske vlade od veljače do travnja 2011. godine koristili su Twitter i Facebook kako bi koordinirali, regrutirali i informirali svoje sljedbenike. Inicijativa za pokretanje prosvjeda pokrenuta je putem Facebook fan stranice Veliki prosvjed za rušenje Vlade (<http://www.facebook.com/prosvjed>). Prosvjedi su se održavali diljem Hrvatske. Međutim, najbrojniji su bili oni

u glavnom gradu Zagrebu. Prosvjedi su okupili veliki broj različitih političkih organizacija s ekstremne ljevice i desnice, nevladinih organizacija i građana kojima je jedino zajedničko bilo rušenje vlade (Čadež, 2011).

Zagrebački prosvjedi su se održavali u dvodnevnim terminima i njihov maksimum je ostvaren 4. ožujka, kada je na prosvjedu sudjelovalo preko 10 tisuća prosvjednika (Trajković et.al, 2011). Osim Facebooka, prosvjednici su aktivno koristili i Twitter. Zbog svih prednosti koje Twitter omogućava, upravo će njegova upotreba od strane hrvatskih aktivista biti predmet istraživanja ovog rada.

Istraživanje je bilo organizirano oko slijedećih istraživačkih pitanja:

1. Tko su najutjecajniji aktivisti koji su koristili Twitter?
2. Koje aktivnosti poduzimaju najutjecajniji aktivistički korisnici?
3. Koje mjere utjecaja određuju najvažnije članove online zajednice?

Metodologija

Prikupljanje podataka za potrebe istraživanja uključivalo je dvije vrste podataka iz primarnih izvora:

- Podaci o aktivističkim Twitter korisnicima (profilima)
- Podaci o aktivističkim Twitter postovima

U prvom slučaju prikupljeni su podaci o korisnicima na dan 9. ožujka 2011. godine. Tim prikupljanjem je obuhvaćeno 347 od ukupno 772 prosvjednika koji su koristili Twitter za objavu na temu prosvjeda u razdoblju od 2. ožujka od 2. travnja 2011. godine, što čini 45,3 posto ukupne populacije. Podaci su prikupljeni upotrebom NodeXL dodatka za Microsoft Excel, a u obzir su uzeti korisnici Twittera koji su objavljivali upotrebom hashtaga #prosvjed.

Za drugu skupinu podataka prikupljanje je obavljano u razdoblju od 2. ožujka do 2. travnja 2011. godine. Prikupljano je 9967 poruka koje su sadržavale hashtag #prosvjed. Za prikupljanje poruka korišten je softver Archivist.

Kako bi se usporedili utjecaji korisnika, upotrijebljen je Sperman's rank koeficijent korelacije koji se temelji na rangui unutar određene mjere.

Rezultati i diskusija

Među deset posto korisnika s najvećim brojem followers dominiraju mediji. Prvo mjesto drži Jutarnji list, slijede Nethr (3.), Radio 101(5.), Tportal(6.), Planbhr(7.), Dnevnik.hr(9.), Novi list(10.), ezadar (12.) i dr. Prvi od osobnih korisnika koji se nalazi među korisnicima s najvećim brojem followers je u stvari spamer demure4you (2.). Slijede poduzetnici Ivo Spigel (8.), Ilija Brajković (13.), medijski producent Ana Balentović (14.) i dr. Zanimljivo je kako među prvih 10 % nema medijskih zvijezda (glumci, pjevači, sportaši...). Kao što je iz prethodnih istraživanja vidljivo (Cha et. al, 2010: 13), broj followers je dobar pokazatelj za utvrđivanje korisnika koji primaju dosta pažnje na osnovu direktne povezanosti korisnika i njegove javnosti. Ipak, ova mjera nije dobar način za prikazivanje utjecaja jer ignorira potencijal korisnika za uzajamno djelovanje sa sadržajem, a pokazuje samo mogućnosti Twittera kao platforme za objavu (Levitt et al., 2009:4). Također, broj followers ne znači da svi korisnici čitaju ono što je objavljeno, tako da možemo govoriti samo o potencijalu koji pojedini korisnik ima (Avnit, 2009).

Iako prijašnja istraživanja pokazuju da Twitter korisnici zahtijevaju od followersa da im postanu prijatelji zbog susretljivosti (Levitt et al., 2009:4), vidimo kako to u slučaju Twitter prosvjednika uglavnom nije slučaj. Od medija se ne očekuje da djeluju po tom principu, pa ipak među prvih 10 % korisnika našli su se Radio 101 (3.), Jutarnji list(5.), planbhr(6.), Tportal(11.), ezadar (15.) i Nethr(17). Prvi je spamer demure4you kojeg prati spamer dubrovnikdriver (4.), a slijede ih osobni korisnici Ivo Spigel (2.) Ilija Brajković (9.), Ana Balentović (12.), Miloš Đajić (13.) i dr. Zanimljivo je da je u ovoj kategoriji prisutan i agregator twtroatia (8.).

Prema ukupnom broju objavljenih tweets, vodeći je Matt Marenić kojeg slijedi spamer demure4you (2.), mediji Dalje.hr (3.), RSS agregator novosti Sajnaires (4.), te korisnici Romanbold (5.), zvjeronika (6.) i Mario Alejandro (7.). Ivo Spigel je osmi, Dubravko Sorić deveti, a slijede ih mediji vijest.hr (10.) i vijestih (11.), ezadar (13.) trafichr (14.), Jutarnji list (16.) i dr.

Iz prethodnih kategorija utjecaja vidimo kako su pojedini korisnici vodeći prema broju followers i friends te broju objavljenih tweets, iz čega možemo zaključiti kako im je cilj prikupljati korisnike kao kontakte kojima će nametati sadržaj, a koji će ga onda dalje promovirati drugim korisnicima. Što je omjer između broja followers i friends bliži nuli to će korisnik biti više kategoriziran kao spammer. Kako navodi Levitt et al.

(2009:5), stereotipski spameri prikupljaju što veći broj followera kako bi im nametali svoj sadržaj. Iz prikazanog primjera vidimo kako spameri mogu biti pojedinci i organizacije.

Također, kod utjecaja Twitter korisnika treba imati na umu da mjere poput followers, friends i Tweets ignoriraju odnos koji postoji između korisnika, sadržaja i platforme (Levitt et al., 2009:8), posebno kada je riječ o tematski ograničenoj upotrebi Twittera.

Za razliku od prethodnih mjera utjecaja, podaci o @, RT i Tweets (#prosvjed) su usko vezani uz temu prosvjeda. Iako se pojedini korisnici iz ovih kategorija nalaze među 10% vodećih unutar kategorija Followers, Friends i Tweets, većina ne spada u tu kategoriju. Iznimke su hbujas, hkomljenovic, krunovidic, mbajkusa, pojemario i forcebook (svoga 5 od 114 mogućih u sve tri kategorije).

Kao što je vidljivo iz Vann grafa, postoji visoko preklapanje između kategorija number of @ drugi korisnici, number of @korisnika, number of RT drugih korisnika, number of RT korisnika te number of tweets (#prosvjed).

U slučaju number of @ drugih korisnika, vidimo da je vodeća missophiae, slijedi ipekarik (2.), hkomljenovic (3.), baky (4.), Kruno Vodić (5.), msperic (6.) i dalje. Od medija među prvih 10 % prisutan je samo Nethr (32) . Iz ovoga je vidljivo da mediji nisu aktivno spominjali druge korisnike, što je i logično s obzirom da je njihov cilj povećati broj korisnika njihovih online izdanja, a ne komunicirati s drugim Twitter korisnicima. Tu tezu nadopunjuju i podaci o @ drugih korisnika, iz kojih vidimo da se u ovoj kategoriji nešto češće se javljaju mediji. Tako su u toj kategoriji Jutarnji list (11.), Nethr (14.), Tportal (17.) i dnevnikhr(23).. Međutim, i dalje je prva missophiae, slijedi je ipekarik (2.), hkomljenovic (3.), baky (4.), Kruno Vodić (5.), Markus Schatten (6.) i dalje. Vidljivo je da se među najspominjanijima nisu našli zvijezde, kao što je to slučaj kod opće populacije Twitter korisnika (Cha et. al, 2010: 13), već korisnici koji su postali virtualni eksperti na temu prosvjeda. Jedine zvijezde koje se spominje su mediji koji su izvještavali o prosvjedima.

Slična pojavnost medija zamijećena je i u kategorijama number of RT drugih korisnika i number of RT korisnika. U prvom slučaju među 10 % uopće nema medija, dok je u drugom slučaju Nethr šesti, a slijede dnevnikhr (12.), Jutarnji list (14.), Tportal (18.) i Radio 101 (22.).

Najviše tuđih poruka prosljedio je Markus Schatten, a slijede ga msperic (2.), dr_hindoo (3.), dpasaric (4.), almightywatashi (5.), inkognitori

(6.) i dalje. Missosphiae je tek osma, a ipekarik devetnaesti. Međutim, vidimo da je najviše poruka autora prosljeđeno od Ipekarik (1.) i missosphiae (2.), a slijede fankuseta (3.), hkomljenovic (4.), msperic (5) i dalje. Treba imati na umu da se prosljeđivanjem poruke povećava mogućnost za prihvaćanje inovacije koja je sadržana u poruci, zbog čega je ova mjera utjecaja vrlo važna.

Prema broju objavljenih tweets na temu prosvjed najveći broj poruka objavio je Markus Schatten, a slijede ga msperic (2.), missosphiae (3.), dr_hindoo (4.), ipekarik (5.), hkomljenovic (6.), frankuseta (6) i dalje. Vidljivo je kako su autori koji su pisali na određenu temu (#prosvjed) postali i virtualni eksperti te da se ti autori najviše spominju i prosljeđuju. Mediji su se našli i u ovoj kategoriji te je, prema boju tweets, među njima najviše objavljivao nethr (9.), dnevnikhr (15.) i jutarnji (33.).

Table 1. Top 10% korisnika

	Number of Followers	Number of Friends	Number of Tweets	Number of @ drugih korisnika	Number of @ korisanika	Number of RT drugih korisnika	Number of RT korisnika	Number of Tweets #prosvjed	
jutarnji	1	demure4you	1	missosphiae	1	missosphiae	1	mschatten	1
demure4you	2	ivospigel	2	ipekarik	2	ipekarik	2	msperic	2
nethr	3	radio_101	3	baky	3	hkomljenovic	3	frankuseta	3
afromusing	4	dubrovnikdri	4	sajnaires	4	krunovic	4	dpasari	4
radio_101	5	jutarnji	5	romanbol	5	mschatten	5	krunovic	5
tportal	6	planbhr	6	zvjeronik	6	hkomljenovic	6	mschatten	6
planbhr	7	webkomsija	7	mbajkusa	7	msperic	7	mbajkusa	7
ivospigel	8	twcroatia	8	ivospigel	8	dr_hindoo	8	frankuseta	8
dnevnikhr	9	ilijabrajkovic	9	sorazg	9	vserbu	9	dr_hindoo	9
novilisthr	10	goranapp	10	vijesti_hr	10	mbajkusa	10	dpasari	10
dubrovnikdri	11	tportal	11	vijesthr	11	dpasari	11	jutarnji	11
ezadar	12	anabalentovic	12	milosdjajic	12	martina_no	12	zriha	12
ilijabrajkovic	13	milosdjajic	13	ezadar	13	badnickname	13	poscounders	13
anabalentovic	14	nebojsag	14	traffichr	14	poscounders	14	nethr	14
milosdjajic	15	ezadar	15	sivinski	15	dpozari	15	almightywas	15
hvojemihajlic	16	hbujas	16	jutarnji	16	sorazg	16	msperic	16
mbajkusa	17	nethr	17	zriha	17	almightywas	17	tportal	17
sivinski	18	turtlewoman	18	gliby432	18	ladykarmy	16	hbujas	17
goranapp	19	ambroseand	19	marin_os	19	bruno_afk	19	vserbu	17
nebojsag	20	lafamiliafilm	20	pojemarki	20	shenuo	19	shenuo	17
zvjeronika	21	la__kat	20	markobozic	21	mrenic	21	prosvjednik	17
hbujas	22	antlenazbn	22	forcebook	22	inkognitori	22	martina_no	22
zriha	23	mbajkusa	23	southsouth	23	ivospigel	23	dnevnikhr	23

marin_ostojic	24	pojemario	24	sakisneus	24	bitstring3k	23	bruno_alk	23	oseloth	24	sloser	24	oseloth	24
sorazg	25	zriha	25	topssy	25	prosvjednik	23	vlatkopavlovic	25	glupinickname	25	kmajetic	24	softyare	25
gpeuc	26	topssy	26	iljabrajkoVIC	26	frankuseta	26	badnickname	25	fpzghr	26	prosvjednik	26	badnickname	26
viborc	27	sorazg	27	hrvojemihajlic	27	tzombix	26	ivospigel	27	kmohi	26	zriha	27	brankavukovic	27
akeglovichorvat	28	idapandur	28	itsmarkian	28	goranapp	28	mrenic	27	kljaric	26	kljaric	27	prosvjednik	28
hkomljenovic	29	cairenn	29	hkomljenovic	29	hbujas	28	inkognitori	27	dpozaric	26	hr_pirate	27	beno_hr	29
lafamilafim	29	vanfranco	30	gpeuc	30	zriha	28	sdphrvatske	30	nethr	30	tzombix	30	dpozaric	29
torbica	31	forcebook	31	akeglovichorvat	31	dsohar	28	panonski	30	frankuseta	30	dpozaric	30	ladykarmy	31
topssy	32	vrhunsko	32	dragalepgetic	32	rethr	32	miljenkoo	30	ssuljic	30	kojkar	30	kmohi	32
romanbold	33	fpzghr	33	anabalenovic	33	hrvojemihajlic	32	nebojsag	33	dmalway	30	sorazg	33	jutarnji	33
krunovidic	34	marin_ostojic	34	viapatka pa	34	brankavukovic	32	vanai	33	prosvjednik	30	almightywashtashi	33	hr_pirate	34
obi_rjecki	35	evaracdin_hr	35	tportal	35	fjuman	32	sloser	33	poscounderhill	30	lclabincom	33	tinahrvatska	35
pojemario	36	obi_rjecki	36	peolou	36	replacement2011	32	ladykarmy	33	zli_patuljak	36	panonski	33	bitstring3k	35
antenzgbnews	37	hrvojemihajlic	37	zubarica	37	skadinna	32	novilisthr	37	amadeus111	36	fjuman	33	kmajetic	37
sloba_milosevic	38	petarv	38	portaloko	38	kegnatz	32	softyare	37	radio_101	38	vanai	38	zriha	38

Postoji vrlo visoka korelacija između broja prijatelja i followers $Rho=0.853$ te ukupnog broja tweets i followera $Rho=0.809$. Nešto je manja korelacija $Rho=0.632$ između broja prijatelja i broja tweets. Međutim, nije utvrđena statistički značajna povezanost između navedene tri mjere utjecaja i preostalih mjera utjecaja. Ovakvi rezultati nisu u skladu s prijašnjim istraživanjima koja su pokazala da kod opće populacije postoji stvarno značajna povezanost između broja followers i RT i @. Cha et. al (2010: 13) to pojašnjava umjetnom povezanošću korisnika s najmanjim utjecajem. Kod 10% najutjecajnijih korisnika podaci su slični dobivenim ovim istraživanjem. Dakle, nema statistički značajne povezanosti.

S druge strane, postoji vrlo visoka povezanost $Rho=0.949$ između korisnika koji spominju druge i koji su spominjani što se može protumačiti s naravi takve vrste aktivnosti, koja proizlazi iz diskusija i komuniciranja putem Twitter platforme. Također, postoji vrlo visoka korelacija $Rho=0.911$ između korisnika koji se spominju i korisnika čije se poruke prosljeđuju te korisnika koji spominju druge i korisnika čije se poruke prosljeđuju $Rho=0.877$. Iz ovoga možemo zaključiti kako je riječ o najvažnijim mjerama za utvrđivanje utjecaja korisnika na Twitteru.

Statistički vrlo značajna korelacija postoji između korisnika koji prosljeđuju poruke i korisnika čije se poruke prosljeđuju $Rho=0.799$. Broj tematskih tweets u značajnoj je korelaciji sa sve četiri mjere utjecaja koje proizlaze iz RT i spominjanja.

Iz ovih rezultata proizlazi da se, generalno gledano, vrlo često prosljeđuju poruke korisnika koji se često spominje. Ovo vrijedi i za obratni odnos. Također, možemo zaključiti da korisnik s najvećim brojem prijatelja i followera ne znači nužno i da je najutjecajniji kada je u pitanju

pokretanje rasprava na određenu temu ili prosljeđivanje poruka. Slične rezultate utvrdili su i Cha et. al (2010: 13)

Table 2. Rho korelacije između različitih mjera utjecaja na Twitteru

	Number of Followers	Number of Friends	Number of Tweets	Number of @ drugih korisnika	Number of @ korisnika	Number of RT drugih korisnika	Number of RT korisnika	Number of Tweets #prosvjed
Number of Followers	-	0.853	0.809	0.219	0.258	0.253	0.300	0.137
Number of Friends	0.853	-	0.632	0.220	0.256	0.286	0.291	0.188
Number of Tweets	0.809	0.632	-	0.204	0.240	0.226	0.252	0.072
Number of @ drugih korisnika	0.219	0.220	0.204	-	0.949	0.767	0.877	0.579
Number of @ korisnika	0.258	0.256	0.240	0.949	-	0.786	0.911	0.630
Number of RT drugih korisnika	0.253	0.286	0.226	0.767	0.786	-	0.799	0.773
Number of RT korisnika	0.300	0.291	0.252	0.877	0.911	0.799	-	0.753
Number of Tweets #prosvjed	0.137	0.188	0.072	0.579	0.630	0.773	0.753	-

Iz rezultata korelacije vidljivo je kako postoje dvije vrste mjera utjecaja koje proizlaze iz Twittera kao platforme, te ponašanja korisnika:

- Opći utjecaj
- Tematski utjecaj.

U prvom slučaju utjecaj se određuje na temelju broja followers, friends i Tweets. Ovakav način određivanja dobar je za određivanje najvažnijih Twitter korisnika u općoj populaciji. S druge strane, tematski utjecaj određen je brojem tweets na određenu temu, RT I @. Ovakva vrsta utjecaja bitna je za određivanje tko su najvažniji twitter korisnici s obzirom na određenu temu – u slučaju ovog istraživanja aktivisti koji su objavljivali na temu antivladinih prosvjeda.

Cha et. al (2010: 17) kažu kako se utjecaj ne ostvaruje spontano ili slučajno, već da se ostvaruje kroz određeni napor. Kako bi ga ostvarili, korisnici moraju konstantno biti aktivni na Twitteru, temeljem čega ih se može lako identificirati radi utvrđivanja emerging influential users.

Zaključak

Istraživanjem je utvrđeno kako postoje dvije vrste utjecajnih korisnika koje proizlaze iz mjera utjecaja što su uzete u obzir. Tako razlikujemo utjecajne korisnike Twittera opće populacije i tematski ograničene populacije.

Da bi ostvarili utjecaj, Twitter korisnici će biti prijatelji i followers te objavljivati veliki broj tweets. Također će prosljeđivati poruke (RT) i diskutirati te komunicirati (@) s drugim korisnicima.

Ovisno kojoj skupini korisnika pripadaju, koristit će se različite mjere za utvrđivanje utjecaja, kao što je i utvrđeno ovim istraživanjem.

Literatura

Avnit, Adi. The Million Followers Fallacy(2009). URL: <http://pravdam.com/2009/08/20/the-million-followers-fallacy-guest-post-by-adi-avnit/> (19.4.2011.)

Cha, Meeyoung; Haddadi, Hamed; Benevenuto, Fabricio; Gummadi, Krishna P.(2010). Measuring User Influence in Twitter: The Million Follower Fallacy. U: Proceedings of Fourth International AAAI Conference on Weblogs and Social Media. URL: <http://www.aaai.org/ocs/index.php/ICWSM/ICWSM10/paper/view/1538/1826> (11.04.2011.)

Čadež, Tomislav (2011) Što je ovo? Crvena ili crna revolucija? Ne slažu se ni oko čega, osim oko odlaska Vlade. URL: <http://www.jutarnji.hr/sto-je-ovo--crvena-ili-crna-revolucija--ne-slazu-se-ni-ok-odega--osim-da-zele-odlazak-/929459/> (06.04.2011.)

Fidler, Rodger. Mediamorphosis. Beograd: Clio.

Levitt, Alex; Burchard, Evan; Fisher, David i Gilbert, Sam (2009) The Influentials: New Approaches for Analyzing Influence on Twitter. URL: <http://www.webecologyproject.org/wp-content/uploads/2009/09/influence-report-final.pdf> (19.04.2011.)

Pearanalytics (2009) Twitter Study – August 2009. URL: <http://www.pearanalytics.com/blog/wp->

content/uploads/2010/05/Twitter-Study-August-2009.pdf
(11.04.2011.)

Petz, Boris (2002) *Osnove statističkih metoda za nematematičare*. Zagreb: Naklada Slap.

Trajković, Sergej; Panić, Velibor; Deželić, Vanja i Kukec, Tomislav (2011) Prosvjed protiv Vlade: Čak 10.000 ljudi marširalo Zagrebom, privedeno sedam osoba. URL: <http://www.jutarnji.hr/organizatorinajavili-najmasovniji-prosvjed-protiv-vlade/929353/> (06.04.2011.)

Watts, Duncan J. i Dodds, Peter Sheridan (2007) Influentials, Networks, and Public Opinion Formation, *Journal of consumer research*, 37: 441-458.