Povezanost participativnog novinarstva i rezultata izbora splitskog gradonačelnika 2013. godine

Matijaca, Danira

Doctoral thesis / Disertacija

2019

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zadar / Sveučilište u Zadru**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:162:298750

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Image not found or type unknown

Repository / Repozitorij:

University of Zadar Institutional Repository

Image not found or type unknown

SVEUČILIŠTE U ZADRU

POSLIJEDIPLOMSKI SVEUČILIŠNI STUDIJ

DRUŠTVO ZNANJA I PRIJENOS INFORMACIJA

Danira Matijaca

POVEZANOST PARTICIPATIVNOG NOVINARSTVA I REZULTATA IZBORA SPLITSKOG GRADONAČELNIKA 2013.GODINE

Doktorski rad

Zadar, 2019.

SVEUČILIŠTE U ZADRU

POSLIJEDIPLOMSKI SVEUČILIŠNI STUDIJ
DRUŠTVO ZNANJA I PRIJENOS INFORMACIJA

Danira Matijaca

POVEZANOST PARTICIPATIVNOG NOVINARSTVA I REZULTATA IZBORA SPLITSKOG GRADONAČELNIKA 2013. GODINE

Doktorski rad

Mentorica
prof. dr. sc. Nada Zgrabljić Rotar

Zadar, 2019.

SVEUČILIŠTE U ZADRU

TEMELJNA DOKUMENTACIJSKA KARTICA

I. Autor i studij

Ime i prezime: Danira Matijaca

Naziv studijskog programa: Društvo znanja i prijenos informacija

Mentorica: prof. dr. sc. Nada Zgrabljić Rotar

Datum obrane: 05. srpnja 2019.

Znanstveno područje i polje u kojem je postignut doktorat znanosti: Društvene znanosti; Informacijske i komunikacijske znanosti

II. Doktorski rad

Naslov: POVEZANOST PARTICIPATIVNOG NOVINARSTVA I REZULTATA IZBORA SPLITSKOG GRADONAČELNIKA 2013. GODINE

UDK oznaka: 070.1(497.5Split)“2013“

Broj stranica:196

Broj slika/grafičkih prikaza/tablica: 15/57/62

Broj bilježaka:

Broj korištenih bibliografskih jedinica i izvora: 118

Broj priloga:

Jezik rada: hrvatski

III. Stručna povjerenstva

Stručno povjerenstvo za ocjenu doktorskog rada:

1. doc. dr. sc. Vesna Kalajžić, predsjednica
2. prof.dr.sc. Nada Zgrabljić Rotar, članica
3. izv. prof. dr. sc. Josip Ćirić, član

Stručno povjerenstvo za obranu doktorskog rada:

1. doc. dr. sc. Vesna Kalajžić, predsjednica
2. prof.dr.sc. Nada Zgrabljić Rotar, članica
3. izv. prof. dr. sc. Josip Ćirić, član

UNIVERSITY OF ZADAR

BASIC DOCUMENTATION CARD

I. Author and study

Name and surname: Danira Matijaca

Name of the study programme: Društvo znanja i prijenos informacija

Mentor: Professor Nada Zgrabljić Rotar, PhD

Date of the defence: 05. srpnja 2019.

Scientific area and field in which the PhD is obtained: Social sciences: Information and communication sciences

II. Doctoral dissertation

Title: RELATIONSHIP BETWEEN PARTICIPATIVE JOURNALISM AND RESULTS OF SPLIT MAYORAL ELECTION IN 2013

UDC mark: 070.1(497.5Split)“2013“

Number of pages: 196

Number of pictures/graphical representations/tables: 15/57/62

Number of notes:

Number of used bibliographic units and sources: 118

Number of appendices:

Language of the doctoral dissertation: croatian

III. Expert committees

Expert committee for the evaluation of the doctoral dissertation:

1. Assistant Professor Vesna Kalajžić, PhD, chair
2. Professor Nada Zgrabljić Rotar, PhD, member
3. Associate Professor Josip Ćirić, PhD, member

Expert committee for the defence of the doctoral dissertation:

1. Assistant Professor Vesna Kalajžić, PhD, chair
2. Professor Nada Zgrabljić Rotar, PhD, member
3. Associate Professor Josip Ćirić, PhD, member

Izjava o akademskoj čestitosti

Ja, **Danira Matijaca,** ovime izjavljujem da je moj **doktorski** rad pod naslovom **Povezanost participativnog novinarstva i rezultata izbora splitskog gradonačelnika 2013. godine** rezultat mojega vlastitog rada, da se temelji na mojim istraživanjima te da se oslanja na izvore i radove navedene u bilješkama i popisu literature. Ni jedan dio mojega rada nije napisan na nedopušten način, odnosno nije prepisan iz necitiranih radova i ne krši bilo čija autorska prava.

Izjavljujem da ni jedan dio ovoga rada nije iskorišten u kojem drugom radu pri bilo kojoj drugoj visokoškolskoj, znanstvenoj, obrazovnoj ili inoj ustanovi.

Sadržaj mojega rada u potpunosti odgovara sadržaju obranjenoga i nakon obrane uređenoga rada.

Zadar, 12. srpnja 2019.

Sadržaj

Predgovor iv
I. Istraživački problem v
II. Cilj istraživanja, istraživačka pitanja i hipoteze viii
III. Metode istraživanja ix
IV. Predviđeni doprinos istraživanja xii
1. Uvod 1
1.1.Javna sfera 1
1.1.1 Povijest nastanka javne sfere 1
1.1.2 Suvremena javna sfera 3
1.1.3 Internetska javna sfera 6
1.2 Participativno novinarstvo 9
1.2.1 Mrežno novinarstvo 9
1.2.2 Oblici mrežnog novinarstva 10
1.2.3 Definicija participativnog novinarstva 12
1.3 Konverzacija građana na internetu 14
1.3.1 Konverzacija kao oblik diskursa 14
1.3.2 Definicija javne rasprave 16
1.3.3 Odlike javne rasprave 18
1.3.4 Struktura konverzacije građana na internetu 19
1.3.5 Određivanje razine javne rasprave na Internetu 22
1.4 Javno mnijenje 23
1.4.1 Definicije javnog mnijenja 24
1.4.2 Uloga javnog mnijenja u javnoj sferi 25
1.4.3 Istraživanja javnog mnijenja 26
1.4.4 Dubinsko istraživanje mnijenja na internetu 28
1.4.5 Semantička orijentacija (SO) teksta 29
1.5 Dosadašnja istraživanja 31
1.5.1 Konverzacija na Internetu 31
1.5.2 Analiza sentimenata 36
2. Metodologija 40
2.1.Studija više slučajeva 40

2.2.Odabir i pohrana uzorka 45
2.3.Sadržajna analiza..... 47
2.3.1. Kategorizacija odlika kandidata..... 47
2.3.2. Jedinice analize 51
2.3.3. Tablice i obrasci za unos podataka 52
2.3.4. Analiza sentimenata 54
2.3.5. Analiza argumenata 56
2.3.6. Analiza strukturalnih pokazatelja konverzacije 57
2.4.Obrada podataka 58
3. Rezultati istraživanja 62
3.1.Rječnik za analizu sentimenata 62
3.2. Portal 24 sata 63
3.2.1. Analiza sentimenata 63
3.2.2. Odlike kandidata 66
3.2.3. Odlike konverzacije 72
3.2.4. Teme, sentimenti i polemičnost konverzacije..... 72
3.3. Portal Indeks 74
3.3.1. Analiza sentimenata 74
3.3.2. Odlike kandidata 77
3.3.3. Odlike konverzacije 83
3.3.4. Teme, sentimenti i polemičnost konverzacije..... 84
3.4.T-portal..... 85
3.4.1. Analiza sentimenata 85
3.4.2. Odlike kandidata 88
3.4.3. Odlike konverzacije 94
3.4.4. Teme, sentimenti i polemičnost konverzacije..... 94
3.5.Portal Slobodna Dalmacija..... 96
3.5.1. Analiza sentimenata 96
3.5.2. Odlike kandidata 99
3.5.3. Odlike konverzacije 105
3.5.4. Teme, sentimenti i polemičnost konverzacije..... 106
3.6.Portal Dalmacija News..... 108
3.6.1. Analiza sentimenata 108

3.6.2. Odlike kandidata 111
3.6.3. Odlike konverzacije 117
3.6.4. Teme, sentimenti i polemičnost konverzacije 118
3.7.Usporedba novinskih portala 119
3.7.1. Broj objavljenih članaka o kandidatima 120
3.7.2. Zastupljenost komentara o kandidatima i građanima novinarima 122
3.7.3. Broj građana novinara 124
3.7.4. Analiza sentimenata 126
3.7.5. Odlike kandidata 133
3.7.6. Odlike konverzacije 136
3.7.7. Sličnosti populacija korisnika na različitim portalima 139
3.7.8. Povezanost participativnog novinarstva i izbornih rezultata 140
3.8.Sažetak rezultata 144
4. Diskusija 147
4.1.Konverzacija građana novinara na novinskim portalima 147
4.2.Sentimenti izraženi prema kandidatima 151
4.3.Povezanost participativnog novinarstva i izbornih rezultata 154
4.4.Ograničenja istraživanja 157
4.5.Daljnja istraživanja 159
5. Zaključak 161
Popis korištenih izvora i literature 165
Sažetak 182
Summary 183
Životopis 184

Predgovor

Javna sfera, onako kako ju je opisao Habermas (1996), predstavlja mrežu za izmjenu informacija i stavova između različitih skupina u društvu. Budući da proces primanja i prenošenja poruka pomoću oblikovanja misli u komunikaciji Zymnaja (2001, navedeno u Milevskaya, 2002) definira kao diskurs, a Dooley i Levninsohn (2000, pp. 1-8) konverzaciju opisuju kao diskurs u kojem sudjeluje više osoba, možemo kazati da je javna sfera prostor konverzacije između različitih skupina u društvu. Pojava interneta omogućila je rast apstraktne javne sfere za koju je karakteristično da u njoj sudjeluje veliki broj građana koji se uopće ne moraju poznavati (Habermas, 1996). Pojavljuje se i novi oblik novinarstva na mreži (eng. online) koje se naziva mrežno novinarstvo (eng. online journalism) u kojem ulogu novinara preuzimaju obični građani (Deuze, 2003). Građani novinari na internetu objavljuju informacije i izražavaju stavove o različitim temama na mrežnim mjestima (eng. web sites) poput blogova, foruma i novinskih portala. Kada građani novinari posve samostalno djeluju na mrežnim mjestima koje su sami pokrenuli, poput blogova i foruma, takva se vrsta mrežnog novinarstva naziva građansko novinarstvo (eng. citizen journalism) (Friedland & Kim, 2009), a kada surađuju s profesionalnim novinarima i djeluju na mrežnim mjestima vodećih novinskih kuća takav se oblik mrežnog novinarstva naziva participativno novinarstvo (eng. participatory journalism) (Henig, 2005; Nip, 2006, Friedland & Kim, 2009). Primjer mrežnog mjesta novinskih kuća su novinski portali na kojima građani novinari mogu pisati komentare uz objavljene novinske članke. Građani novinari pišući komentare na novinskim portalima mogu stupati u konverzaciju jedni s drugima te izraziti stavove o različitim temama, pa tako i o političarima u vrijeme predizborne kampanje. U tom su slučaju komentari građana novinara na novinskim portalima izvor informacija o odlikama njihove konverzacije i stavovima koje izražavaju prema političarima. Konverzacija se građana na internetu može vizualno predočiti pomoću radijalnog stabla u kojem je u centru početna poruka na koju se nadovezuju odgovori u prvom sloju konverzacije, a zatim odgovori na odgovore u prvom sloju, što čini drugi sloj konverzacije, itd.(Gomez et al., 2008). Korisne informacije o odlikama konverzacije građana na internetu mogu se dobiti i na temelju proučavanja strukture konverzacije: ukupnog broja poruka u konverzaciji, broja sudionika u konverzaciji, dubine postignutog sloja i sl. (Gonzales – Bailon et al., 2010); kao i na temelju analize sadržaja poruka (Park & Cardie, 2014). Komentari građana novinara na novinskim portalima mogu poslužiti i za istraživanje dubinskog javnog mnijenja (eng. opinion mining) ili analizu sentimenata (eng. sentiment analysis) koji se

mogu definirati kao prosudbe i ideje obojane emocijama (Boiy et al., 2007, p. 350). Analiza sentimenata može se provoditi automatski pomoću računalnih programa (Ding et al., 2008; Tumitan i Becker, 2013; Balasubramanyan et al., 2012), što je područje istraživanja računarske lingvistike (eng. computational linguistics - CL), pomoću tehnika obrade prirodnog jezika (eng. natural language processing- NLP) ili ručno (Carvalho et al, 2011; Abdula et al., 2014), što predstavlja zlatni standard na temelju kojeg se procjenjuje uspješnost računalnih programa (Meguebli et al., 2014). U analizi sentimenta ključno je utvrditi jesu li sentimenti izraženi u nekom tekstu pozitivni ili negativni te koliko su snažno izraženi, pa se analiza sentimenata može provesti i tako da se tekstu u kojem je izražen sentiment pridruži pozitivna ili negativna brojčana vrijednost koju onda nazivamo semantička orijentacija (eng. semantic. orientation – SO). Sentimenti se izražavaju prema entitetima ili prema njihovim aspektima, a entitete mogu predstavljati proizvodi, osobe ili događaji (Liu, 2012). Semantička se orijentacija nekog teksta dobiva tako da se u tekstu pronađu riječi i izrazi koji izražavaju sentimente i onda se zbroje vrijednosti SO riječi i izraza koji izražavaju sentiment (Ding et al., 2008). Pri ručnoj analizi sentimenata često se izrađuju leksikoni u kojima su navedeni riječi i izrazi koji izražavaju sentimente s pripadajućim brojčanim vrijednostima SO (Balasubramanyan et al., 2012).

U ovom su istraživanju primijenjene metode studije više slučajeva (eng. cross- case analysis) kao poseban oblik studije slučaja (eng. case study) te sadržajna analiza komentara građana novinara na novinskim portalima. Za analizu sentimenata izraženih u komentarima i odlika konverzacije građana novinara na novinskim portalima odabrano je pet hrvatskih novinskih portala: 24 sata, Indeks, T-portal, Slobodna Dalmacija i Dalmacija News. Analiza je sentimenata izvršena ručno, a odlike konverzacije utvrđene su na temelju strukturalnih pokazatelja konverzacije i analizom sadržaja komentara.

I. Istraživački problem

Prije pojave interneta ulogu posrednika u konverzaciji između građana i vlasti imali su profesionalni novinari koji su tradicionalno filtrirali i obrađivali informacije, a onda ih objavom u različitim medijima činili dostupnima u javnoj sferi. Na taj su način profesionalni novinari imali ulogu „gatekeeper"-a, osoba koje su odlučivale o propuštanju informacija, kao i o obliku u kojem su se one pojavljivale u javnoj sferi (Delli Carpini & Williams, 2001). Pojava interneta značajno je promijenile karakteristike javne sfere i omogućila izravnu komunikaciju između velikog broja građana. S jedne strane slabi uloga novinara u ulozi „gatekeeper"-a, jer sada svi

građani mogu objavljivati različite informacije na internetu, a s druge se suočavamo s mnoštvom informacija, za koje ne znamo jesu li točne, kao i s grupiranjem građana u virtualne skupine koje razmišljaju na sličan način, zbog čega dolazi do polarizacije mišljenja u samim skupinama (Sunstein, 2007). Uz rastuću, mogli bismo reći i masovnu internetsku sferu koja povezuje mnoštvo građana diljem svijeta, dobili smo i novo mrežno i masovno novinarstvo u kojemu svaki građanin koji komentira ili objavljuje informacije na internetu postaje građanin novinar, više ili manje posve samostalan u svojim aktivnostima. Suočavamo se s mnoštvom informacija, tekstova i u tekstualnom obliku arhiviranih konverzacija građana koje postaju bogat izvor informacija za dubinsko istraživanje javnog mnijenja (eng. opinion mining) ili analize sentimenata (eng. sentiment analysis) izraženih u tekstovima dostupnim na internetu (Liu, 2012) .

Osim za istraživanje javnog mnijenja dostupni tekstovi na blogovima, forumima i novinskim portalima mogu nam poslužiti i za određivanje odlika konverzacije građana na internetu te na temelju toga i za određivanje razine deliberativne demokracije u nekoj zajednici. Naime, upravo je javna rasprava (eng. public deliberation) kao specifični oblik konverzacije u kojem svi građani mogu podjednako sudjelovati i za koju je poželjno da u njoj budu izraženi različiti stavovi i interesi građana i skupina u društvu, temelj na kojem počiva deliberativna demokracija (Kim et al., 1999; Habermas,1991). Osim mogućnosti jednakopravnog uključivanja svih građana u raspravu i poželjne što veće heterogenosti izraženih mišljenja (Stromer – Galley, 2007), važna je odlika javne rasprave i dobra argumentiranost, što pretpostavlja visoku interaktivnost sudionika u konverzaciji putem postavljanja pitanja i odgovaranja na njih te iznošenja argumenata i protuargumenata. Ukupno povećanje broja građana koji sudjeluju u konverzaciji na internetu pozitivna je promjena koja može poboljšati kvalitetu konverzacije i približiti je idealu javne rasprave, ali upitno je koliko su u skupinama u kojima se odvija internetska konverzacija građana izraženi različiti stavovi i, ako jesu, koliko su uopće sudionici u konverzaciji spremni na promjenu mišljenja kad se suoče s dobrim argumentima. Upravo je spremnost na promjenu stava ključna da bi javna rasprava postigla svoj cilj – postizanje konsenzusa oko tema od zajedničkog interesa (Habermas, 1991, p. 41). Uz ovaj cilj, premda pomalo djeluje entuzijastično, veže se i Kantova (navedeno u Habermas, 1991, p. 118) misao da su rasprave kamen temeljac istine i da sve što se proklamira kao istina testira svoju istinitost pred svakim razumnim ljudskim bićem. Drugo je ključno pitanje koliko sudionici u konverzaciji na internetu koriste dobre argumente, gdje se dobrim ili racionalnim smatra onaj argument u kojem su tvrdnje utemeljene na empirijski provjerljivim dokazima ili

na opće prihvaćenim načelima (Stromer-Galley, 2007, p. 4). Jednak pristup svima i sloboda izražavanja (Graham, 2008), kao preduvjeti koje je nužno ispuniti da bi se konverzacija smatrala javnom raspravom, više su ili manje zadovoljeni na internetu, ali koliko su stvarno sudionici u konverzaciji spremni slušati druge i uvažiti njihove argumente odgovarajući protuargumentima, vrlo je upitno, pogotovo kada se uzme u obzir činjenica da brojna istraživanja ukazuju na to da nezanemariv udio, negdje i oko 40 % sadržaja konverzacije građana na internetu ima uvredljiv karakter (Ruiz et al., 2011). Umjesto dobrih argumenata građani se često služe „ad hominem" argumentima kojima napadaju jedni druge, umjesto da „napadnu" tuđi argument svojim protuargumentom (Kišiček, 2013). U tom se slučaju u konverzaciji može postići visoka interaktivnost koja se očituje u porukama koje se izmjenjuju jedna nakon druge kao odgovor na prethodnu, ali budući da sadržaj takvih poruka ima uvredljiv karakter u tom slučaju visoka interaktivnost ne ukazuje na kvalitetnu javnu raspravu. Nadalje, visoka interaktivnost u konverzaciji ne očituje se samo u brojnosti poruka koje predstavljaju odgovor na prethodne, nego i u brojnosti sudionika koji sudjeluju u razmjeni poruka. U kvalitetnoj bi javnoj raspravi što veći broj sudionika trebao stupiti u interakciju jedni s drugima, izmjenjujući međusobno argumente i protuargumente, čime bi se izbjegla centraliziranost konverzacije ili dominacija malog broja sudionika (Graham, 2008).

Dosadašnja istraživanja pokazala su da konverzacije građana na internetu uglavnom nemaju odlike javne rasprave, jer su slabo argumentirane (Park & Cardie, 2014; Noci et al., 2012; Weger i Aaakhus, 2003; Jansen, 2014) i njima dominira mali broj sudionika (Noci et al., 2012; Collins & Nerlich, 2015; Gode et al., 2015), da izražena mišljenja nisu dovoljno heterogena (Ruiz et al, 2011; Milioni et al., 2012), pa se može govoriti i o izraženoj polarizaciji mišljenja na različitim mrežnim mjestima. Nadalje, građani novinari tijekom konverzacije često pišu uvredljive komentare i omalovažavaju jedni druge (Erjavec & Poler-Kovačič, 2013; Richardson & Stanyer, 2011; Ruiz et al., 2011; Milioni et al., 2012; Papacharissi, 2004; Weger & Aaakhus, 2003) što je povezano s nedostatnom argumentiranošću konverzacije. Sentimenti koje izražavaju prema političarima uglavnom su negativni (Abdulla et al., 2014; Tumitan & Becker, 2013; Carvalho et al., 2011), a udio pozitivnih i negativnih sentimenata izraženih u konverzaciji o političarima povezan je s javnim mnijenjem koje se očituje kroz rezultate izbora, s tim da postoji bolja povezanost između udjela pozitivnih sentimenata i izbornih rezultata nego li između udjela negativnih sentimenata i izbornih rezultata. Nadalje, na novinskim je portalima uočena i povezanost između broja komentara o političarima i izbornih rezulatata, zbog čega se može kazati da je uočena povezanost između participativnog novinarstva i javnog mnijenja

(Tumitan & Becker, 2013). Rezultati istraživanja odlika konverzacije i analize sentimenata razlikovali su se od portala do portala (Ruiz et al., 2011; Balasubramany et sl., 2012), a neki su istraživači izrazili optimizam s obzirom na deliberativni potencijal konverzacija građana novinara na internetu, ali on se odnosi na manju skupinu građana (Manosevitch & Walker, 2009; Collins & Nerlich, 2015).

II. Cilj istraživanja, istraživačka pitanja i hipoteze

Cilj je ovog istraživanja bio opisati konverzaciju građana novinara na pet hrvatskih novinskih portala i utvrditi koliko takva konverzacija ima odlike javne rasprave, te na temelju analize sentimenata izraženih u komentarima utvrditi postoji li povezanost između mnijenja građana novinara na istraživanim portalima i izbornih rezultata. Pri tom su postavljena sljedeća pitanja:

a) Postoji li povezanost između participativnog novinarstva na istraživanim novinskim portalima i javnog mijenja?
b) Postoji li povezanost između broja građana novinara na istraživanim novinskim portalima koji se pozitivno izjašnjavaju o kandidatu i izbornih rezultata?
c) Postoji li povezanost između broja građana novinara na istraživanim novinskim portalima koji se negativno izjašnjavaju o kandidatu i izbornih rezultata?
d) Što motivira građane novinare za participaciju na istraživanim novinskim portalima?
e) Postoje li razlike između komentara građana novinara na istraživanim novinskim portalima?
f) Ima li konverzacija "građana novinara" odlike javne rasprave na istraživanim hrvatskim novinskim portalima?

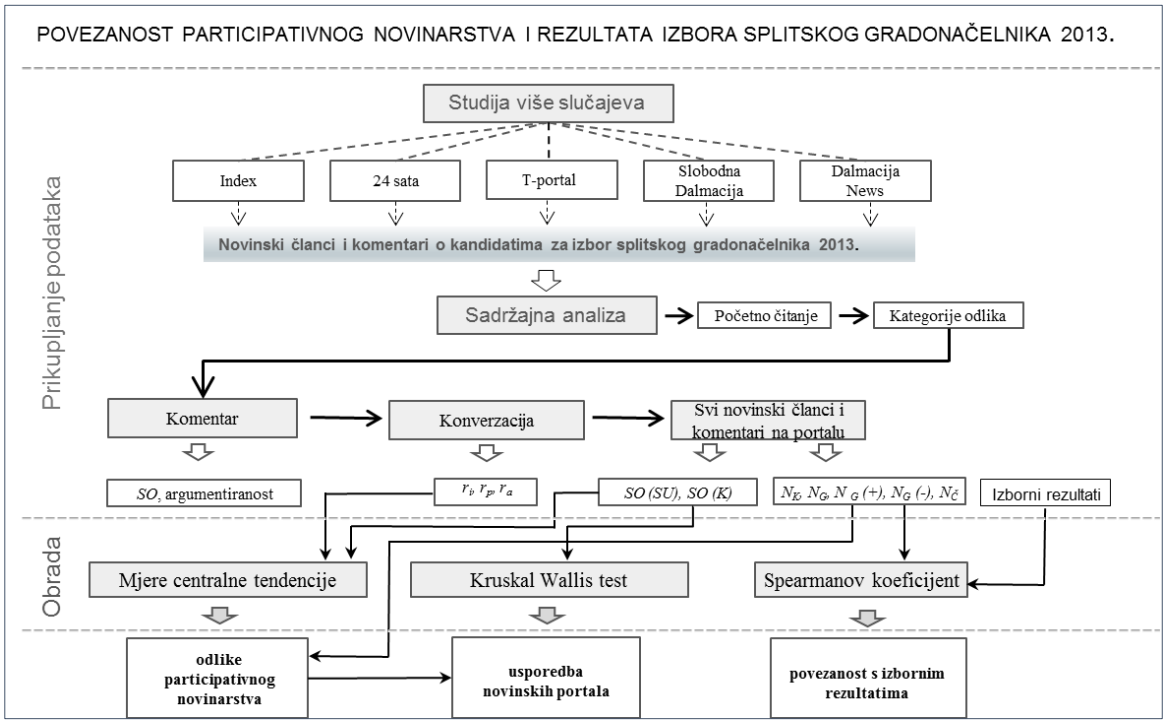
U istraživanju su postavljene hipoteze:

- H1 Na istraživanim novinskim portalima postoji povezanost participativnog novinarstva i izbornih rezultata
- H2 Na istraživanim novinskim portalima postoji povezanost između broja građana novinara koji se pozitivno izjašnjavaju o kandidatu i izbornih rezultata
- H3 Na istraživanim novinskim portalima postoji povezanost između broja građana novinara koji se negativno izjašnjavaju o kandidatu i izbornih rezultata
- H4 Na istraživanim novinskim portalima motivi građana za participaciju pretežito su negativni stavovi prema kandidatima

- H5 Komentari građana novinara pokazuju sličnosti na svim istraživanim portalima
- H6 Konverzacija građana novinara na svim istraživanim portalima imala je nisku razinu javne rasprave

III. Metode istraživanja

U ovom kvantitativnom istraživanju primijenjen je pozitivistički pristup, jer su unaprijed postavljene hipoteze i testirane su razlike među skupinama, a istraživane su se varijable brojčano određivale (Kazdin, 1998, navedeno u Milas, 2005). Varijable koje Vujević (1992: 92) definira kao „promjenljiva obilježja o kojima u hipotezama nešto tvrdimo“ u ovom su istraživanju bili: SO komentara građana novinara o kandidatima, te strukturalni i sadržajni pokazatelji konverzacije: razina interaktivnosti, razina polemičnosti i razina argumentiranosti. Sve su varijable bile kvantitativne, jer su se brojčano izražavale i mijenjale (Hoskin, 2012).



Dijagram 1. Tijek istraživanja povezanosti participativnog novinarstva i rezultata izbora

Dijagram 1. prikazuje tijek istraživanja u kojem su primijenjene dvije metode prikupljanja podataka: studija više slučajeva i sadržajna analiza. Uočeno je pet kategorija novinskih portala i nakon toga je odabran onaj koji je prema podacima agencije gemiusAudeince imao najviše posjeta u razdoblju od 01. siječnja do 19. svibnja 2013., kada je

završio prvi izborni krug za izbor splitskog gradonačelnika. Odabrano je duže razdoblje od same predizborne kampanje budući da su neki političari kandidaturu objavili i prije službenog početka kampanje. Odabrani su novinski portali: 24 sata (nacionalni portal s dnevnim izdanjem tiskane novine i s prosječno mjesečno 20,8 milijuna posjeta), Index (nacionalni portal bez dnevnog izdanja tiskane novine i s prosječno mjesečno 21,3 milijuna posjeta), T-portal (nacionalni portal čijem izdavaču nije primarna djelatnost medijsko izdavaštvo i s prosječno mjesečno 12,4 milijuna posjeta), Slobodna Dalmacija (regionalni portal s dnevnim izdanjem tiskane novine i s prosječno mjesečno 3,9 milijuna posjeta), Dalmacija News (regionalni portal bez dnevnog izdanja tiskane novine i s prosječno mjesečno 1,5 milijuna posjeta). Nacionalnim novinskim portalima smatrali su se oni čija se redakcija uredništva nalazila u Zagrebu, a regionalnima oni čija se redakcija uredništva nalazila u Splitu. Svih pet novinskih portala razlikovalo se i prema prosječnom mjesečnom broju posjetitelja.

Neki su se novinski članci odnosili na jednog kandidata, što je bilo razvidno iz naslova u kojem su bili spomenuti kandidat, njegovi partneri ili projekti koje je pokrenuo, a neki su se odnosili na više kandidata i općenito na izbore, pa su označeni kao zajednički (ZAJ). Krajem lipnja 2013. s odabranih su novinskih portala pohranjena 674 novinska članka s pripadajućim komentarima, a bili su zajednički ili su se odnosili na kandidate za izbor splitskog gradonačelnika: Željka Keruma *(KER)*, Ivu Baldasara *(BAL)*, Vjekoslava Ivaniševića *(IVA)*, Anđelku Visković *(VIS)*, Sanju Bilač *(BIL)*, Marijanu Puljak *(PULJ)*, Hrvoja Tomasovića *(TOM)*, Tomislava Zaninovića *(ZAN)*, Damira Vidoševića *(VID)*, Marija Popovića *(POP)* i Peru Vučicu *(VUČ)*. Za većinu je novinskih članaka postojala mogućnost pisanja komentara i oni su se pohranjivali u MS Access bazu podataka, a prilikom pohrane komentara izostavljeni su prvi i svi pripadajući dublji slojevi konverzacije ukoliko se u prvom sloju komentari nisu odnosili na kandidate. Na taj je način na svih pet istraživanih portala pohranjeno ukupno 15 715 komentara napisanih u 604 konverzacije uz novinske članke. Za prikupljanje podataka primijenjena je metoda sadržajne analize u kojoj je za potrebe mjerenja razina polemičnosti i interaktivnosti konverzacija jedinicu analize predstavljala konverzacija građana novinara uz članak, a činili su je svi komentari uz taj članak, dok je za potrebe mjerenja argumentiranosti i *SO* komentara jedinicu analize predstavljao svaki pojedini komentar. Građani su novinari ponekad komentirali i one kandidate koji nisu bili spomenuti u samom članku, pa su na svakom novinskom portalu za utvrđivanje broja građana novinara koji su komentirali kandidata N_G i broja komentara o kandidatu N_K, jedinicu analize predstavljali svi novinski članci o svim

kandidatima i pripadajući komentari pohranjeni u istraživanom razdoblju na tom novinskom portalu.

Za svaku je konverzaciju izmjeren *h - index* , definiran kao najveći redni broj sloja konverzacije *j* u kojem je bilo barem *j* komentara. Za mjerenje r_p konverzacije primijenila se formula Gomeza et al. (2008):

$$r_p = h - index \quad + \frac{1}{n_k}, \tag{1}$$

gdje je r_p razina polemičnosti, a n_k ukupan broj komentara u konverzaciji.

Razinu je interaktivnosti r_i predstavljao postotak komentara u konverzaciji koji su bili odgovori na prethodne, a određivao se na temelju odnosa broja komentara koji nisu pripadali prvom sloju i ukupnog broja komentara u konverzaciji.

Razinu je argumentiranosti r_a konverzacije predstavljao postotak komentara koji su u konverzaciji bili argumentirani. Komentar se smatrao argumentiranim ukoliko je u njemu bila navedena provjerljiva činjenica, osobno iskustvo ili općeprihvaćeno načelo.

Pri utvrđivanju *SO* komentara uočeni su izrazi i riječi koji izražavaju sentimente, te je tijekom analize izrađen rječnik s 4913 takvih riječi i izraza. Tijekom početnog čitanja komentara uočeno je da građani novinari prema kandidatima izražavaju sentimente u odnosu na nekoliko kategorija: pružanje potpore *PO*, sposobnost *SP*, pristojnost *PR*, odgovornost *OD*, moralnost *MO*, izgled *IZ*, domoljublje *DO* i kriminalnost *KR*. Građani su novinari izražavali sentimente i jedni prema drugima, pa su riječi i izrazi koji su ih izražavali uvršteni u kategoriju sudionici *SU*. Za sve su se riječi i izraze u rječniku odredile kategorije kojoj pripadaju, te im se pridruživale vrijednosti 1, ukoliko je sentiment bio pozitivan, ili -1, ukoliko je sentiment bio negativan. Ukupna *SO* komentara u pojedinoj kategoriji dobivala se zbrajanjem prema formuli:

$$SO\ (kategorija) = \sum_i^n SO\ (w_i), \tag{3}$$

gdje je *SO (kategorija)* ukupna *SO* komentara u pojedinoj kategoriji; *n* predstavlja ukupni broj riječi i izraza koji izražavaju sentimente u toj kategoriji; a *SO* (w_i) predstavlja *SO* tih riječi i izraza.

Ukoliko je komentar bio ironičan, što se utvrđivalo analizom svih komentara određenog građanina novinara, tada su riječi i izrazi koji izražavaju sentimente imale *SO* suprotnog predznaka od onog koji je naveden u rječniku.

Pri obradi podataka za svaki su portal izračunate mjere centralne tendencije za r_i, r_p i r_a konverzacija, gdje je broj mjerenja bio jednak broju konverzacija, tj. broju objavljenih

novinskih članaka u kojima je postojao barem jedan komentar. Na svakom je novinskom portalu za svakog građanina novinara, na temelju zbrajanja ukupnih *SO* komentara po u pojedinim kategorijama, izračunata ukupna *SO* komentara o pojedinom kandidatu *SO (K)*, te ukupna *SO* komentara o drugim građanima novinarima *SO (SU)*. Izračunate su i mjere centralne tendencije *SO (K)* i *SO (SU)*, gdje je broj mjerenja bio jednak broju građana novinara na tom portalu. Za svaki je novinski portal izmjeren broj članaka o pojedinom kandidatu $N_{Č}$, broj građana novinara koji su ga komentirali N_G, ukupni broj komentara o njemu N_K, te na temelju pozitivne ili negativne *SO (K)*, broj građana novinara koji su prema njemu bili pozitivno N_G *(+)* ili negativno orijentirani N_G *(-)*. Budući da se stavovi u populaciji građana ne pojavljuju prema normalnoj distribuciji, raspodjele rezultata za *SO (K)* i *SO (SU)* na svim su istraživanim portalima uspoređivane pomoću Kruskal- Wallis testa koji se primjenjuje pri usporedbi neparametrijskih varijabli u više skupina (novinskih portala) u kojima ne postoji isti broj mjerenja. Na novinskim portalima na kojima su komentirani svi kandidati primjenom neparametrijskog Spearmanovog koeficijenta korelacije ranga utvrđena je povezanost broja glasova koje su kandidati dobili nakon prvog izbornog kruga i varijabli participativnog novinarstva: N_G *(+)*, N_G *(-)*, $N_{Č}$, N_G *i* N_K.

IV. Predviđeni doprinos istraživanja

Proučavanje participativnog novinarstva novo je područje interesa suvremene komunikologije, pa se ovim istraživanjem nastojalo:

a) produbiti razumijevanje nedovoljno istražene participacije građana u hrvatskom medijskom prostoru
b) definirati metodologiju istraživanja participativnog novinarstva na hrvatskim portalima
c) dobiti nove spoznaje o načinu sudjelovanja specifičnog dijela medijske publike koja bi mogla postati važnim nositeljem izražavanja javnog mnijenja.
d) dobiti izvorne znanstvene rezultate koji mogu pridonijeti razumijevanju digitalne medijske kulture.

1. Uvod

Pojava interneta omogućila je nastanak internetske javne sfere i novu vrstu novinarstva u kojem ulogu novinara preuzimaju obični građani. Pišući komentare (eng. comments), objave (eng. posts) ili osvrte (eng. reviews) građani izražavaju sentimente o različitim temama, osobama ili proizvodima. Takvi sadržaji postaju predmetom dubinskog istraživanja mnijenja (eng. opinion mining) na temelju analize sentimenata (eng. sentiment analysis) dostupnih u tekstu (Liu, 2012). U ovom će poglavlju biti pojašnjeni pojmovi javne sfere, javne rasprave, javnog mnijenja, novih oblika novinarstva na internetu, dubinskog istraživanja javnog mnijenja i analize sentimenata.

1.1. Javna sfera

Kao područje komunikacije između različitih društvenih sektora suvremena je javna sfera složena, prožeta raznovrsnim načinima komuniciranja i velikim brojem sudionika. Podijeljena je s obzirom na različite teme komunikacije, raznovrsne skupine sudionika i različite medije putem kojih se ostvaruje komunikacija. Kada je o politici i donošenju zajedničkih odluka riječ u idealnom je Habermasovu (1996) modelu javna sfera zamišljena kao prostor u kojem privatne osobe artikuliraju svoje interese pred predstavnicima javnih vlasti, a onda se kroz racionalnu komunikaciju postiže konsenzus i donose odluke koje su obvezujuće za sve. I dok su nekada glavni i gotovo jedini nositelji posredovanja u komunikaciji između građana i predstavnika vlasti bili novinski mediji, danas internet omogućuje uključivanje velikog broja građana u neposredniju komunikaciju s političarima i drugim građanima, zbog čega se razvija i novi oblik demokracije koji nazivamo elektroničkom demokracijom (Clift, 2003).

1.1.1. Povijest nastanka javne sfere

Habermas (1991), analizirajući različite uloge i odlike javne sfere kroz povijest, podsjeća da se podrijetlo današnjeg značenja izraza „javna sfera“ nalazi u staroj Grčkoj. U visokorazvijenim gradovima – državama postojala je sfera zajednička svim građanima (polis) i sfera koja je predstavljala privatnu sferu svakog pojedinca (oikos). Dvije sfere bile su strogo odvojene, a život javnosti (bios politikos) odvijao se na tržnici (agora). Javna je sfera označavala prostor interakcije međusobno ravnopravnih pojedinaca i stvarala se kroz rasprave

(lexis) i zajednička djelovanja (praxis), poput ratovanja i sportskih natjecanja. Kroz razdoblje Srednjeg Vijeka pojmovi privatne i javne sfere do nas su stigli preko definicije Rimskog prava u kojem se za javnu sferu koristio izraz „res publico“ (Habermas, 1991, pp. 3-4). Od sredine 16. stoljeća riječ „privatno“ odnosila se na sve što nije imalo veze s državnim uredima ili službama, a riječ „javno“ se odnosila na državu. Sama država postala je entitet koji je postojao zasebno i bez osobe vladara (Habermas, 1991, p. 11.). Tek u 18. stoljeću nakon pojave snažnih nacionalnih država koje su nastale na temeljima rane kapitalističke ekonomije i koje su dokinule feudalne izvore moći, stvoreni su preduvjeti za jasno odvajanje privatne i javne sfere. Vidljivi znak ovih promjena bilo je odvajanje javnog proračuna od privatnog vlasništva vladara, osamostaljenje vojske i birokracije koje su postale institucije podložne javnoj vlasti. Različite organizacije postale su dijelom civilnog društva koje je kao izvorno područje privatne autonomije bilo suprotstavljeno državi (Habermas, 1991, pp. 11-12). Podređivanje ekonomske aktivnosti zahtjevima tržišta doprinijelo je drugačijem i jasnijem razgraničenju privatne i javne sfere, budući da ekonomija više nije bila isključivo vezana uz oikos. Nadalje, pojava tiskanih novina koje su se od sredine 17. stoljeća izdavale svaki dan pospješila je afirmaciju javne sfere kao zasebnog prostora u kojem se komuniciraju sadržaji od javnog interesa, a novine su stavljene u službu državne administracije. Državni su službenici (suci, liječnici, svećenici, profesori i znanstvenici), veliki trgovci, bankari i osnivači poduzeća zauzeli središnju poziciju u javnoj sferi (Habermas, 1991, pp. 19-24). Riječ „javnost“ (eng. public) u Velikoj se Britaniji počela koristiti tek od sredine 17. stoljeća, a prije toga su u uporabi bile riječi „čovječanstvo“ (eng. mankind) i „svijet“ (eng. world). U Francuskoj i Njemačkoj prije riječi „javnost“ koristili su se izraz „svijet čitatelja“ ili jednostavno riječ „svijet“ (Habermas, 1991, p. 26).

Javnu je sferu u 18. stoljeću sačinjavala: politička javna sfera iz koje su bile isključene žene i sluge, a bavila se političkim pitanjima te literarna javna sfera u kojoj su mogle sudjelovati i žene i sluge, a bavila se pitanjima vezanim uz objavljenu literaturu. Politička je javna sfera preuzela od literarne modele foruma i rasprava, a omogućavala je građanima da izraze svoje potrebe pred državnim vlastima, postajući tako sferom kritike koju je javnost kao skupina privatnih osoba sa zajedničkim interesima upućivala onima koji su obnašali vlast (Habermas, 1991, p. 74.). Civilno je društvo pripadalo području privatne sfere i kao takvo, u vrijeme 18. stoljeća i na počecima stvaranja buržujskog društva i kapitalizma, okupljalo je privatne osobe sa zajedničkim interesima vezanima uz tržište (Habermas, 1991, pp. 51-55). Sudstvo i državna administracija postale su dio javnih vlasti (eng. public authorithy), a privatna sfera nije bila podređena pravilima državnih vlasti već zakonima tržišta, zbog čega su vlasnici dobara mogli slobodno i samostalno upravljati svojom imovinom (Habermas, 1991, p. 74.). Na jednoj su

strani bili predstavnici javne vlasti koji su donosili i provodili državne zakone, a na drugoj vlasnici dobara zainteresirani za pitanja tržišta i robne razmjene, a javna je sfera bila područje njihove međusobne komunikacije o pitanjima koja su se odnosila na tržište kao temeljenog nositelja funkcioniranja kapitalističkog modela društva. Država je u takvom društvu davala opće norme i zakonima garantirala opće slobode svima, štiteći na taj način funkcioniranje slobodnog tržišta. Prema buržujskoj ideji države utemeljene na zakonu svi su zakoni trebali biti rezultat racionalno argumentirane komunikacije u javnoj sferi, a ne puke političke volje ili bilo čije dominacije (Habermas, 1991, pp. 80-82).

> Ustavna država kao buržujska država stvorila je javnu sferu na području politike kao vlastiti mehanizam koji je osiguravao institucionalnu vezu između zakona i javnog mnijenja. (Habermas, 1991: 81)

Ustav je štitio prava građana na slobodu govora i mišljenja, slobodno udruživanje, potpisivanje peticija i glasovanje te slobodu novinarstva. Na taj je način održavao javnu sferu kao specifičan prostor komunikacije između građana i predstavnika javnih vlasti, a političke stranke i novinarstvo bili su institucije i instrumenti javne sfere pomoću kojih je ona ispunjala svoju ulogu (Habermas, 1991, p. 83). Tako su stvoreni temelji liberalnih demokracija koje, osim neovisnosti javne sfere, odlikuje i privatna autonomija građana, slobodno i jednakopravno uključivanje građana u političku zajednicu, periodički izbori i referendumi, nadmetanje između različitih političkih stranaka i programa te donošenje političkih odluka na temelju glasovanja većine u zastupničkim tijelima (Habermas, 2006, p. 412).

1.1.2. Suvremena javna sfera

I dok se u 18. stoljeću s nastankom buržujskog društva i liberalnog kapitalizma dogodilo jasno razgraničavanje privatne i javne sfere, od sredine 19. stoljeća pa nadalje područja privatnog i javnog ponovno se isprepliću. Političko jačanje i osvješćivanje siromašnijih društvenih struktura koje su počele komunicirati u javnoj sferi državu je primoralo da zaštiti stabilnost sustava štiteći prava „slabijih“. Privatno vlasništvo i načini sklapanja ugovora, koji su prije toga pripadali samo području privatne sfere, gube apsolutnu autonomiju i slobodu te postaju uvjetovani zakonskim ograničenjima i standardima koje je određivala država. Područje privatne sfere koje se odnosilo na ekonomiju postaje sve više javno i do danas je taj trend zadržan. Samo područje koje se ne odnosi na obavljanje posla, bilo u privatnom poduzeću ili u javnoj instituciji, spada isključivo u privatnu sferu, a javna je sfera, kako objašnjava Habermas

(1996, p. 367), povezana s privatnom na način da upravo iz privatne dobiva poticaje za bavljenje društvenim problemima. Razlika između privatne i javne sfere nije toliko u temama kojima se bave koliko u načinu komunikacije, pa je tako u javnoj sferi komunikacija javna i odvija se među osobama koje se privatno uopće ne moraju poznavati, a u privatnoj se nastoji sačuvati intimnost pojedinca i komunikacija se odvija unutar kruga obitelji, prijatelja i poznanika.

Habermas (1996, p. 373) uočava da je suvremena javna sfera vrlo složena, obuhvaća mnoštvo područja koja se međusobno preklapaju i može se definirati kao „mreža za izmjenu informacija i stavova" (Habermas, 1996: 360). Ukoliko ovakvu definiciju javne sfere povežemo s Perloffovom (1998, navedeno u Hoffman, 2006: 63) definicijom politike kao „procesa tijekom kojeg skupina ljudi čija su početna mišljenja ili interesi različiti donose zajedničke odluke koje su obvezujuće za sve u skupini i provode se kao zajednička politika", politička se javna sfera može definirati kao mreža za izmjenu informacija i stavova skupine ljudi različitih početnih mišljenja ili interesa tijekom procesa donošenja zajedničkih odluka obvezujućih za sve u skupini. U centru su političkog sustava: zastupnička tijela, sudovi, državna administracija i Vlada, a na periferiji je javna sfera „isprepletena mrežom za protok poruka – vijesti, izvještaja, komentara, razgovora, prikaza i slika, te emisija i filmova s informativnim, polemičkim, edukativnim ili zabavnim sadržajem" (Habermas, 2006: 415). U teoretskom konceptu modernih liberalnih demokracija javna je sfera neovisno područje u kojem se odvija posredovanje između države i društva, a odlikuje se „raznovrsnošću neovisnih masovnih medija te pristupom i uključivanjem mnoštva građana" (Habermas, 2006: 412). Bez medija koji prenose vijesti nije moguće funkcioniranje političkog sustava u demokratskim društvima, budući da takvi mediji prenose poruke političara i time omogućuju političku komunikaciju između centra političkog sustava i periferije – javnosti (Ha, 2003, str. 330). Javnost se oslanja na medije koji prenose vijesti, ne samo da bi dobila informacije o političkim temama, već da bi dobila i informacije o načinima razmišljanja o pojedinim temama i političarima. Upravo odabirom pojedinih tema mediji koji prenose vijesti utječu na formiranje političkih stavova i na sliku koju zajednica ima o sebi kao o zajednici (McCombs, 1997, str. 442.). Međutim, treba naglasiti da nije riječ o jedinom utjecaju, već jednom od utjecaja, budući da su

> politički stavovi i djelovanja rezultat interpretacije novih informacija kroz leće prijašnjih pretpostavki i uvjerenja, a te su leće društveno konstruirane od cijelog niza zajedničkih kulturalnih izvora (Delli Carpini & Williams, 2001: 161)

Održavanje predizbornih kampanja kao dijela demokratskih procesa nije moguće bez novinarstva. Kako kampanja napreduje vijesti o pojedinim kandidatima sve su učestalije i

iscrpnije, a utjecaj novinarstva na javnost veći je kad javnost manje zna o pojedinim kandidatima. U slučaju kad kandidati ulažu velika sredstva u političku promidžbu i kada su u medijima znatno zastupljeni sadržaji koji se odnose na te kandidate, glasači o njima često raspravljaju u krugu rodbine, prijatelja i poznanika, tako da mediji donekle gube utjecaj na stvaranje i tijek rasprava o pojedinim kandidatima. Kada su kandidati manje poznati, što je češći slučaj na lokalnim izborima, mediji koji prenose vijesti postaju glavni predvoditelji i pokretači stvaranja rasprava o njima te na taj način više utječu na sam tijek kampanje (Ha, 2003, str. 330).

Moderna je javna sfera diferencirana s obzirom na: teme kojima se bavi, organizacijsku složenost i učestalost komunikacije te se mogu uočiti (Habermas, 1996, p. 374):

a) javna sfera s privremenom publikom, poput one u kafićima, tavernama ili na ulici
b) javna sfera s prigodnom ili dogovorenom publikom, poput one na koncertima, predstavama i sl.
c) apstraktna javna sfera koju čine izdvojeni čitatelji, slušatelji i gledatelji na velikom geografskom prostoru povezani putem masovnih medija

Sudionike javne sfere Habermas (1996, p. 364) definira kao osobe ili skupine koje djeluju u tom prostoru, a možemo ih podijeliti u temeljne dvije kategorije: one koji stvaraju i održavaju javnu sferu, a dolaze iz same javnosti te one koji zauzimaju već stvorenu javnu sferu radi ostvarenja svojih interesa. Kao tipični sudionici javne sfere mogu se izdvojiti (Habermas, 2006, pp. 416-417):

a) urednici i novinari
b) političari
c) lobisti koji zastupaju posebne interesne skupine i u javnu se sferu uključuju s određenim ciljem
d) zagovornici koji zastupaju opće interesne skupine ili marginalne društvene skupine, a osobni ugled nisu stekli u nekom području znanosti ili umjetnosti te dolaze iz sfere civilnog društva
e) stručnjaci za određeno područje čija je funkcija davanje savjeta i u javnu se sferu uključuju na zahtjev sudionika
f) moralisti koji usmjeravaju pozornost javnosti na zanemarene teme, a osobni ugled nisu stekli u nekom području znanosti ili umjetnosti te dolaze iz sfere civilnog društva

g) intelektualci koji su osobni ugled stekli u nekom području znanosti ili umjetnosti, a u javnu se sferu uključuju spontano radi općeg interesa te dolaze iz sfere civilnog društva

1.1.3. Internetska javna sfera

U suvremenom društvu Habermas (1996, p. 374) uočava rast apstraktne javne sfere u koju se uključuje sve veći broj ljudi, a Dahlgren (2005: 160) zaključuje da je internet u prvom planu javne sfere koja evoluira i da „specifične javne sfere koje zbog toga nastaju omogućuju građanima da se uključe u razvoj novih demokratskih politika". Sama definicija politike se mijenja (Dahlgren, 2005, p. 151), javljaju se novi oblici političkog pritiska, promjene u strategiji komuniciranja i novi oblici aktivizma (Graber et al., 2002, p. 92). Politička je scena u internetskoj javnoj sferi turbulentnija i njome se teže upravlja (Blumler & Gurewitch, 2001, p. 3), komunikacija se zasniva na izmjeni pisanih poruka, koje su manje formalne i sličnije su govornoj komunikaciji nego li onoj u tiskanim medijima, a identitet sudionika je nejasan (Janssen & Kies, 2005, p. 3). Pozitivna je posljedica pojave apstraktne sfere stvaranje mogućnosti za necentraliziranu, otvorenu i slobodnu komunikaciju u kojoj svatko može sudjelovati, bez vremenskih i prostornih ograničenja te bez cenzure (Janssen & Kies, 2005, p. 2; Bailon et al., 2010, p. 1). Nove mogućnosti komunikacije mogu dovesti do intenzivnijeg političkog angažmana građana, a upoznavanje s drugačijim mišljenjima do veće tolerancije prema onima koji misle drugačije i do stvaranja veće razine povjerenja prema njima (Bailon et al., 2010, p. 1). Kao pozitivan učinak evoluirane sfere Dahlgren (2005, p. 151) uočava porast broja političkih glasova, dok Galston (2003, navedeno u Dahlgren, 2005. p. 152) negativnom posljedicom smatra stvaranje mnoštva komunikativnih podgrupa koje se mogu izolirati ili poticati na nesnošljivost prema drugačijima, čime se stvaraju odvojeni „otoci političke komunikacije". Dahlgren (2005, p. 152) takve komunikacijske skupine naziva kibernetskim getima koji mogu štetiti integrirajućoj društvenoj funkciji javne sfere. Na tu pojavu upozorava i Sunstein (2007) kada uočava da komunikacija istomišljenika dovodi do tzv. „ekstremizma enklava" ili polarizacije grupe na internetu ili izvan njega, a očituje se time da stavovi pripadnika takvih skupina nakon komunikacije postaju još izraženiji u onom smjeru u kojem je na početku skupina bila usmjerena. Još jednu negativnu stranu internetske javne sfere uočavaju Blumler i Gurewitch (2001, p. 3) kada zaključuju da povećanje broja autora medijskih sadržaja može proizvesti kakofoniju kao posljedicu medijske prezasićenosti i porasta broja političkih

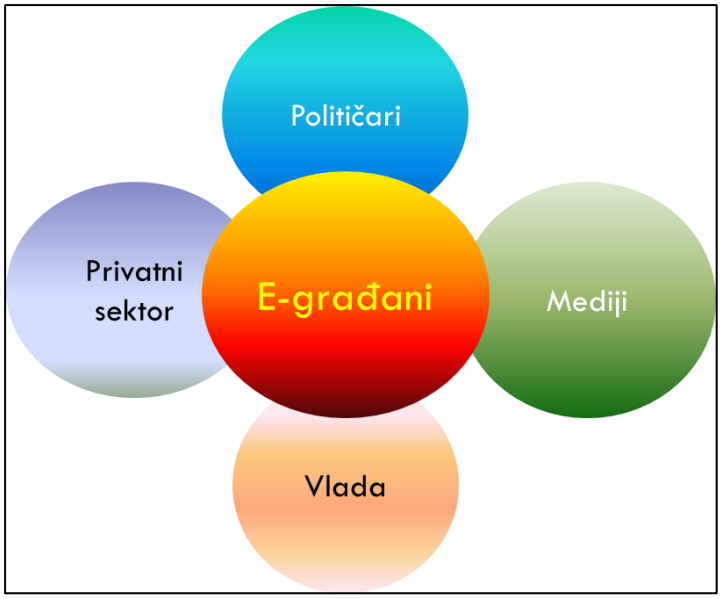
sudionika i posrednika. Neki su autori posve optimistični kada je riječ o utjecaju internetske javne sfere na demokraciju, pa ističu da ona omogućava veću vidljivost političkim manjinama, a mogućnost da građani budu anonimni vide kao pozitivnu odliku, jer se na taj način može postići iskrenija i slobodnija komunikacija (Grossman, 1995; Levy, 2002, navedeno u Janssen & Kies, 2005, p. 3). S druge pak strane, dio je autora pesimističan, jer uočavaju da velik dio populacije nije uključen u političku komunikaciju na internetu, a rasprave se zbog mogućnosti da građani komuniciraju anonimno često pretvaraju u svađe i vrijeđanja (Davis, 1999; Maldonado, 1997, navedeno u Janssen & Kies, 2005, p. 3).

U novim je okolnostima autoritet profesionalnih novinara i samih političara kao tradicionalnih političkih „gatekeeper"-a ozbiljno ugrožen od strane same javnosti koja sve više sudjeluje u kreiranju političkog i društvenog značenja određenih zbivanja (Delli Carpini & Williams, 2001, p. 161). Izraz „gatekeeper" prvi je put upotrijebio socijalni psiholog Kurt Lewin (1947, navedeno u Barzilai-Nahon, 2008: 1493), pri tom misleći na „osobe koje kontroliraju protok informacija", što bi se u prostoru javne sfere izravno odnosilo na novinarske urednike, a neizravno na sve koji pokušavaju utjecati na odabir objavljenih informacija i način njihova objavljivanja. Dio autoriteta s tradicionalnih političkih „gatekeeper"-a prešao je na neke nove ili dosada marginalne skupine, kao i na neke nove vrste medija, što Fiske (navedeno u Delli Carpini & Williams, 2001, p.172) naziva pojavom multiaksijalnosti.

> Tradicionalno, autoritet je dosada uglavnom bio ograničen na političku ekonomsku i društvenu elitu: izabrane zastupnike, glasnogovornike velikih interesnih skupina, itd. Svi su se oni, u pokušaju da utječu na političke teme zastupljene u medijima koristili pravilima tradicionalnog novinarstva. Međutim, novo je medijsko okružje, s višestrukim točkama pristupa informacijama i kontinuiranim ciklusom objavljivanja vijesti, stvorilo nove mogućnosti za dosad manje istaknute pojedince i skupine da utječu na javne rasprave. (Delli Carpini & Williams, 2001: 174-175)

Pojavom interneta stvoreni su preduvjeti za razvoj tzv. elektroničke demokracije koju karakterizira „uporaba informacijskih i komunikacijskih tehnologija i strategija od strane demokratskih sektora u sklopu političkih procesa na lokalnoj, nacionalnoj ili globalnoj razini" (Clift, 2003). Kao sektore elektroničke demokracije Clift uočava: Vlade, izabrane zastupnike, medije, političke stranke i interesne skupine, organizacije civilnog društva, međunarodne organizacije i građane glasače. Ovdje je potrebno pojasniti da civilno društvo čine „udruženja,

pokreti ili organizacije koje su nastale više ili manje spontano, a cilj im je reakcije na društvene probleme koji se javljaju u privatnoj sferi izdvojiti i udruživanjem pojačati te kao takve prenijeti u javnu sferu“ (Habermas, 1996: 367). Bitna je odrednica civilnog društva da je ono odijeljeno od države i ekonomije, a njegovo postojanje omogućuju temeljna ljudska prava: pravo na slobodno udruživanje i pravo na slobodu govora. Funkcionalnost civilnog društva osiguravaju slobodni mediji u kojima je otvoren pristup svim sastavnicama društva, tako da se „sačuva otvorenost prema suprotstavljenim mišljenjima i reprezentativna različitost glasova“ (Habermas, 1996: 368).



Slika 1. Model elektroničke demokracije (Clift, 2003)

Na slici 1. prikazan je Cliftov (2003) model elektroničke demokracije. Prema tom modelu Vlade omogućuju pristup informacijama i stupaju u elektroničku interakciju s građanima, političke grupacije i stranke pokreću internetske kampanje, a mediji građanima osiguravaju vijesti i navigaciju kroz informacije. Privatni sektor proizvodi softver i tehnologiju i njime upravljaju zahtjevi potrošačkog društva. Može se primijetiti da su demokratski sektori iz Cliftovog modela zapravo sektori apstraktne javne sfere koju opisuje Habermas (1996) te da se ovakav model elektroničke demokracije može prikazati i kao model internetske javne sfere, u kojoj i Dahlgren (2005) uočava različite sektore:

a) e-Vlada, u kojoj predstavnici vlade stupaju u komunikaciju s građanima
b) aktivistička domena, u kojoj komunikaciju oblikuju različite organizacije
c) građanski forumi, u kojima građani komuniciraju između sebe

d) parapolitička domena, u kojoj se komunicira o temama koje nisu izravno političke, ali se odnose na zajedničko dobro i identitet zajednice
e) novinarska domena, u kojoj se izmjenjuju informacije koje potječu od tradicionalnih novinskih kuća i građana koji preuzimaju ulogu neprofesionalnih novinara

Upravo novinarska domena, prema Dahlgrenu (2005, p. 153), predstavlja jezgru internetske javne sfere.

1.2. Participativno novinarstvo

Pojava interneta, osim što je omogućila razvoj i rast apstraktne javne sfere, omogućila je i pojavu novog oblika novinarstva koje se ostvaruje kroz neprofesionalne aktivnosti građana u internetskoj javnoj sferi (Abdul – Mageed, 2008, p. 59). Ovu je vrstu novinarstva Deuze (2003, p. 206) nazvao mrežno novinarstvo (eng. online journalism) u kojem građani novinske sadržaje mogu stvarati posve samostalno ili u suradnji s profesionalnim novinarima. Suradnju s profesionalnim novinarima Henig (2005, navedeno u Thurman & Hermida, 2010, p. 5) opisuje kao manifestaciju participativnog novinarstva (eng. participatory journalism) ili, kako ga neki autori nazivaju (Vobič & Dahlgren, 2013, pp. 15-16), građanski potpomognutog novinarstva (eng. citizen-assisted journalism). Posve samostalnu novinarsku djelatnost građani ostvaruju na mrežnim mjestima (eng. web sites) poput blogova (eng. blogs) i foruma (eng. forums), što Friedland i Kim opisuju (2009, pp. 297 - 300) kao manifestaciju građanskog novinarstva (eng. citizen journalism). Neprofesionalnim novinarskim aktivnostima na internetu građani izražavaju svoje stavove i sudjeluju u međusobnoj konverzaciji, zbog čega takva mrežna mjesta postaju suvremene virtualne agore.

1.2.1. Mrežno novinarstvo

„Novinarstvo 2.0“ izraz je koji se počeo koristiti nakon što je Tim O‘Reilly (2005, navedeno u Abdul – Mageed, 2008, p. 61) smislio izraz „Web 2.0“ i definirao ga kao mrežnu platformu koja povezuje uređaje, isporučuje aplikacije i računalne programe koji se kontinuirano ažuriraju, koristi i kombinira podatke iz više izvora te se zasniva na tzv. „arhitekturi participacije“. Bit je te platforme interaktivnost u kojoj se od korisnika dobivaju podaci na temelju kojih se poboljšava sustav i tako poboljšan neprestano ažurira te nudi korisnicima. Novinarstvo 2.0 predstavlja manifestaciju platforme Web 2.0 i odnosi se na

uporabu novih tehnologija u stvaranju i analizi vijesti, i to od strane laika - neprofesionalnih novinara koji imaju minimalne vještine potrebne za objavljivanje na mreži (Abdul – Mageed, 2008, p. 59). I ovdje je naglasak na participaciji korisnika koji svojim intervencijama sudjeluju u stvaranju medijskih sadržaja. Interaktivnost, koja je preduvjet realizacije ovog oblika novinarstva, ostvaruje se na sljedeće načine: lakšom navigacijom kroz mrežna mjesta, postavljanjem foruma za diskusije i provođenjem mrežnih anketa, omogućavanjem odabira načina navigacije i pružanjem mogućnosti korisnicima da pišu komentare na objavljene sadržaje.

Ovaj novi oblik novinarstva razvija se u okolnostima krize demokracije i neovisnog profesionalnog novinarstva čija je etika utemeljena na: pružanju točnih informacija, transparentnom djelovanju, odgovornosti i nepristranosti (Vobič & Dahlgren, 2013, p. 10). Kako Vobič i Dahlgren navode, krize demokracije i novinarstva međusobno su uvjetovane i odlikuju se prevladavajućim mišljenjem građana da oni ne mogu utjecati na politiku, zbog čega gube interes za sudjelovanje u političkim procesima. Tradicionalno novinarstvo gubi publiku, a time i gubitak prihoda od reklama, pa novinari, u želji da privuku publiku, sve više primjenjuju strategije stvaranja kratkih i senzacionalističkih vijesti, što narušava načela novinarske etike. Razvoj tehnologije omogućuje da sve veću količinu medijskih sadržaja mogu stvarati neprofesionalni novinari, pa tako i pripadnici različitih interesnih skupina, državnih institucija i vojske, što dodatno dovodi u pitanje primjenu načela profesionalnog novinarstva. No, načela novinarske etike ugrožena su i na drugi način. Naime, u odnosu na profesionalne novinare, građanima novinarima, prema Friedlandu i Kimu (2009, str. 298), manje je jasna razlika između činjenice i mišljenja, zbog čega u sadržaju koji građani novinari stvaraju na internetu dominiraju izražena mišljenja. Također, građani novinari, u odnosu na profesionalne novinare, rjeđe primjenjuju načelo novinarske etike prema kojem je potrebno u novinskom sadržaju iznijeti sve strane priče.

1.2.2. Oblici mrežnog novinarstva

U okolnostima rastuće internetske javne sfere Nip (2006, p. 216) je kategorizirao novinarstvo na sljedeći način:

a) **tradicionalno,** u kojem su profesionalni novinari "gatekeeper"-i koji biraju novinarske teme, a građani su samo izvor informacija
b) **javno,** u kojem građani sudjeluju u stvaranju novinarskih tema i stvaraju vijesti koje prenose profesionalni novinari

c) **interaktivno**, u kojem građani biraju sadržaj koji čitaju ili gledaju
d) **participativno**, u kojem građani mogu ostavljati komentare i pisati vijesti koje su podložne uređivanju i filtriranju profesionalnih novinara
e) **građansko**, u kojem građani stvaraju i uređuju sadržaj, bez upliva profesionalnih novinara

Deuze (2003, p. 206) objedinjuje interaktivno, participativno i građansko novinarstvo u sveobuhvatniji pojam „mrežno novinarstvo“ (eng. online journalism) i definira ga kao novinarstvo u kojem se medijski sadržaji stvaraju prvenstveno radi objave na mreži. Budući da se pod mrežom misli na Internet, u literaturi se može za ovu vrstu novinarstva pronaći i naziv „internetsko novinarstvo“ (Lemann, 2006). Deuze (2003, pp. 205 -206) uočava da mrežni novinari odlučuju o vrsti medijskih formata koji će najbolje prenijeti novinarsku priču, uzimaju u obzir mogućnosti javnosti da odgovori na objavljenu priču, pa čak i da interaktivno utječu na njeno oblikovanje. Također, oni povezuju novinarsku priču s drugim pričama i izvorima pomoću hiperveza (eng. hyperlinks). Stoga su ključne odlike mrežnog novinarstva: uporaba hiperveza, uporaba više vrsta medija i interaktivnost. Nadalje, Deuze uočava četiri oblika mrežnog novinarstva koji se međusobno razlikuju prema razini samostalnosti građana tijekom objavljivanja sadržaja i realiziraju se putem:

a) mrežnih mjesta vodećih novinskih kuća (eng. mainstream news sites)
b) mrežnih mjesta s indeksima i kategorijama (eng. index and category sites)
c) meta mrežnih mjesta za komentiranje (eng. meta and comment sites)
d) mrežnih mjesta za razmjenu i diskusije (eng. share and discussion sites)

Mrežna mjesta vodećih novinskih kuća su, prema Deuzeu (2003, p. 208), najrašireniji oblik mrežnog novinarstva u kojem se korisnicima nudi uglavnom uređeni sadržaj, a mogućnost da sami korisnici utječu na objavljeni sadržaj najmanja je u odnosu na ostale oblike mrežnog novinarstva. Takva mrežna mjesta najčešće održavaju vodeće novinske kuće. U ovu kategoriju spadaju novinski portali, koje Herscovitz (2009, p. 101) definira kao mrežna mjesta s vijestima nalik onima koje su objavljene u tiskanim novinama. Tipično je za novinske portale da su podijeljeni u tematske kategorije i nude niz drugih usluga poput mogućnosti razgovora među korisnicima, pisanja e-maila redakciji i slično. Pri tom je uporaba novinskih portala besplatna, za razliku od tiskanih novina. Thurman i Hermida (2010, p. 6) uočavaju tipične sadržaje novinskih portala u Velikoj Britaniji koje korisnicima omogućuju: stvaranje vlastitih mrežnih stranica, pisanje komentara na novinske članke, odgovaranje na pitanja koja postavljaju novinari ili korisnici portala, sudjelovanje u mrežnim anketama, postavljanje pitanja

novinarima ili osobama koje se intervjuiraju te postavljanje vlastitih video isječaka, fotografija i vijesti.

Mrežna mjesta s indeksima i kategorijama nude hiperveze prema postojećim mrežnim mjestima s novinskim sadržajima, a meta mrežna mjesta za komentiranje posvećena su novinskim medijima i općenito medijima te predstavljaju svojevrsno novinarstvo o novinarstvu ili meta novinarstvo (Deuze, 2003, pp. 209-210). Korisnici najveću mogućnost sudjelovanja u samostalnom kreiranju medijskih sadržaja imaju na mrežnim mjestima za razmjenu i diskusije (Deuze, 2003, p. 210). Primjer za to su blogovi (eng. blogs) koje Tuchman i Ostertag (2008, p.1) definiraju kao mrežna mjesta na kojima pojedinac ili skupina objavljuje sadržaje za koje tvrde da su od općeg interesa. Ovdje pripadaju i internetski forumi (eng. internet forums) koji se još nazivaju i oglasne ploče (eng. message bord), a predstavljaju mrežna mjesta za diskusije čija struktura podsjeća na stablo. Poruke koje korisnici pišu nazivaju se objave (eng. posts), a na početnu objavu i sve odgovore u niti diskusije moguće je stalno odgovarati (Holtz et al., 2012, p.2). Sobe za razgovore (eng. chat rooms) nešto su drugačija mrežna mjesta za razmjenu i diskusiju, jer ovdje se komunikacija vodi simultano i ne postoji mogućnost pisanja poruka i odgovaranja na njih nakon određenog vremena, kao što je to slučaj kod blogova i foruma (Hughes et al., 2016).

1.2.3. Definicija participativnog novinarstva

Građansko su novinarstvo Friedland i Kim (2009, pp. 297 - 300) definirali kao aktivnosti građana koje doprinose komunikaciji u javnoj sferi putem: objave informacija, izvještavanjem i izražavanjem mišljenja na internetu, a tipičan se primjer građanskog novinarstva očituje na blogovima i forumima za rasprave. I Nip (2006) je građansko novinarstvo definirao kao posve samostalne novinarske aktivnosti građana, bez upliva profesionalnih novinara, dok neki drugi autori takav oblik novinarstva smatraju tek oblikom participativnog novinarstva, za koji će Vobič i Dahlgren (2013, p. 15) reći da se očituje kroz suradnju građana s novinskim kućama ili kroz posve samostalno novinarsko djelovanje građana. Suradnja građana s novinskim kućama, prema Vobiču i Dahlgrenu, odvija se tako da građani proizvode sadržaj koji se objavljuje na mrežnim stranicama novinskih kuća, a novinske kuće imaju mogućnost uređivanja tog sadržaja.

Takav oblik participativnog novinarstva oni nazivaju građanski potpomognutim novinarstvom, dok će za posve samostalne novinarske aktivnosti građana reći da one omogućuju (Vobič & Dahlgren, 2013, pp. 15-16):

a) promoviranje interesa lokalne zajednice (lokalno participativno novinarstvo)
b) promoviranje stavova određenih interesnih skupina (advokatsko participativno novinarstvo)
c) promoviranje stavova političkih stranaka i društvenih pokreta s ciljem poticanja društvenih promjena (aktivističko participativno novinarstvo)
d) promoviranje stavova drugačijih od onih koji prevladavaju u vodećim novinskim kućama, uz poštivanje profesionalnih novinarskih načela (alternativno participativno novinarstvo)
e) promoviranje vlastitih stavova putem blogova i društvenih mreža (građansko participativno novinarstvo)

Neki autori samo građanski potpomognuto novinarstvo definiraju kao participativno, dok sve druge oblike nazivaju građanskim novinarstvom, pa tako Henig (2005, navedeno u Thurman & Hermida, 2010, p. 5) upozorava da je potrebno razlikovati novinarsku aktivnost građana podložnu uređivanju od strane profesionalnih novinara koji odabiru i objavljuju sadržaje koje su proizveli građani, što ona naziva participativnim novinarstvom, od onih aktivnosti u kojima građani putem blogova i novinskih mrežnih mjesta koje ne uređuju profesionalni novinari posve samostalno proizvode sadržaje, što ona naziva građanskim novinarstvom.

Može se uočiti da je bitna razlika između participativnog i građanskog novinarstva, onako kako ga razlikuju Henig (2005), Nip (2006) te Friedland i Kim (2009), u intenzitetu interakcije građana i profesionalnih novinara, pa se može zaključiti da je prema definicijama navedenih autora građansko novinarstvo ono u kojem takva interakcija uopće ne postoji. Kada je riječ o novinskim portalima i komentarima koje na njima objavljuju građani, potrebno je uočiti da postoji određena vrsta interakcije građana i profesionalnih novinara. Naime, Reich (2011, p. 98, navedeno u Milioni, 2012, p. 41) je zamijetio da pisanjem komentara građani i dalje ostavljaju tradicionalne novinare u ulozi „glavnog vokala“ te da građani imaju manje važnu i reaktivnu ulogu zbora, budući da novinari pisanjem i objavom novinskih članaka odabiru teme o kojima građani iznose svoja mišljenja u komentarima. Stoga je ovakav oblik mrežnog novinarstva ono što Henig (2005), Nip (2006), Friedland i Kim (2009) definiraju kao participativno novinarstvo ili ono što Vobič i Dahlgren (2013) nazivaju građanski potpomognutim novinarstvom kao posebnim oblikom participativnog novinarstva. Građani

novinari (eng. citizen journalist) definiraju se kao osobe koje vodeće novinske kuće ne plaćaju da bi izvještavale ili pisale na internetu u sklopu blogova, mrežnih mjesta ili foruma (Robinson & DeShano, 2011, p. 965), a aktivnosti se građana novinara mogu opisati kao: prikupljanje, obrađivanje, istraživanje, izvještavanje, analiziranje i objavljivanje vijesti i informacija (Noor, 2016, p. 195).

1.3. Konverzacija građana na internetu

U konverzaciji, kao specifičnom obliku diskursa, građani u internetskoj javnoj sferi razmjenjuju poruke na mrežnim mjestima poput blogova, foruma i novinskih portala. Odlike se takve konverzacije mogu uočiti na temelju strukture konverzacije i sadržaja poruka. Mogu se odrediti interaktivnost i argumentiranost konverzacije, broj sudionika i niz drugih pokazatelja, na temelju kojih možemo odrediti ima li konverzacija na internetu odlike idealne javne rasprave - konverzacije čiji je cilj postići konsenzus između sudionika početno različitih stavova i interesa (Habermas, 1991).

1.3.1. Konverzacija kao oblik diskursa

Pojam diskurs može se definirati na nekoliko načina: kao proces primanja i prenošenja poruka pomoću oblikovanja misli u komunikaciji (Zymnaja, 2001, navedeno u Milevskaya, 2002); kao način govora o svijetu i razumijevanja svijeta (Jørgensen & Phillips, 2002, p.1); kao bilo koji semiotički oblik označavanja, izgovoren, napisan ili vizualan (Bishop & Jaworski, 2003, p. 246); kao praksu govorenja, pisanja i vizualnih predstavljanja te kao proizvod kulture koji se stvara putem proizvodnje, širenja i čitanja teksta (Grant et al., 2005, p. 6, navedeno u Benn & Jones, 2009, p. 1593). Smith (2003) uočava da se diskurs realizira kroz: prepričavanje, opisivanje, izvještavanje, informiranje i argumentiranje. Oblici diskursa razlikuju se s obzirom na: broj sudionika, vrstu sadržaja, način produkcije sadržaja i medij produkcije sadržaja, pa se s tim u vezi diskurs može realizirati kao: monolog, ukoliko sudjeluje samo jedna osoba; konverzacija, ukoliko sudjeluje više osoba; narativni, kada je njegov sadržaj prepričavanje; instrukcijski, kada njegov sadržaj čine upute o tome kako nešto napraviti; bihevioralni, kada njegov sadržaj opisuje kako bi se osobe trebale ponašati, ekspoziturni, kada je njegov sadržaj izlaganje; osobni, kada se sadržaj proizvodi posve slobodno, primjenom osobnog stila izražavanja; društveni, kada se sadržaj proizvodi uvažavajući društveni kontekst uporabe jezika; kao govorenje, kada je medij produkcije sadržaja govor te kao pisanje, kada je medij

produkcije sadržaja pisani tekst (Dooley & Levninsohn, pp. 1-8; Longacre, 1996, navedeno u Dooley & Levninsohn, pp. 1-8). S obzirom na navedenu tipologiju diskursa možemo kazati da je predmet ovog istraživanja bihevioralna, osobna i pisana konverzacija kao vrsta diskursa u kojem sudjeluje više osoba i koji se realizira putem pisanja i uporabom jezika u osobnom stilu, a sadržaj se ovog diskursa odnosi na opisivanje ponašanja političara. Komentari građana na članke objavljene na novinskim portalima mogu se promatrati kao oblik diskursa u kojem se "susreću dva prethodno odvojena diskursa" - diskurs profesionalnih novinara i diskurs građana (Kleut & Milinkov, 2013: 76).

Sami pojmovi konverzacija, dijalog i diskusija u literaturi se često upotrebljavaju kao izrazi sa istim ili sličnim značenjem. Tako Gadamer (1976, navedeno u Ryan & Natalle, 2001) konverzacijom smatra proces postizanja razumijevanja među sudionicima, za Sahoo et al. (2008, p. 3) to je niz poruka razmijenjenih između dvoje ili više ljudi koji razgovaraju o temi od zajedničkog interesa. Izraz diskusija Shemwell i Furtak (2010, p. 223) definiraju kao razmjenu ideja u kojoj više sudionika objašnjava što misle i zašto, a Landsberger (2001, p. 50) kao naizmjenično, ozbiljno i živo nastojanje skupine od dvoje ili više ljudi da razmjene gledišta i sudjeluju u zajedničkoj i recipročnoj kritici. Kristiansen i Bloch-Poulsen (2004, p. 373) dijalog definiraju kao proces u kojem sudionici zajednički nastoje postići bolje razumijevanje onog o čemu razgovaraju, a temelji se na spremnosti sudionika da međusobno podijele svoja znanja i da budu spremni izložiti se riziku promjene svojih stavova. Walton i Krabbe (1995, navedeno u Lewiński, 2010, p. 17) uočavaju šest vrsta dijaloga: uvjeravanje, koje započinje sukobom mišljenja i cilj mu je razriješiti situaciju; istraživanje, koje započinje traženjem dokaza i cilj mu je dokazati hipotezu; pregovaranje, koje započinje sukobom interesa i cilj mu je postići dogovor koji mogu prihvatiti svi sudionici dijaloga; informiranje, koje započinje traganjem za informacijom i cilj mu je razmijeniti informacije; rasprava, koja započinje dilemom vezanom uz izbor i cilj joj je odabrati najbolje od ponuđenog te prijepor, koji započinje osobnim konfliktom i cilj mu je otkriti uzrok sukoba.

Freelon (2010) u internetskoj javnoj sferi uočava tri modela konverzacije građana:

a) liberalno individualistički
b) komunitaristički
c) deliberativni

Liberalno individualistički model karakterizira niska interaktivnost, mali broj sudionika koji dominiraju konverzacijom, svadljivost i sklonost sudionika da pričaju o osobnim iskustvima. Komunitaristički model očituje se u skupini istomišljenika, a odlikuje ga visoka interaktivnost, pozivanje na zajedničko djelovanje i istaknut osjećaj pripadnosti skupini njenih

sudionika. Deliberativni model odlikuje uporaba racionalno kritičkih argumenata, komentiranje tema od javnog interesa, interaktivnost i usmjerenost na temu o kojoj se raspravlja.

Hallin i Mancini (2004) opisali su tri medijska modela koja se razlikuju s obzirom na način konverzacije koja se odvija u njima. Liberalni model konverzacije odlika je Liberalnog medijskog sustava koji ima dužu tradiciju slobode tiska, kojim dominiraju komercijalni mediji, koji je više izložen zakonima tržišta i ima izraženiji novinarski profesionalizam, a tipičan je za Sjevernu Ameriku i Veliku Britaniju (Hallin & Mancini, 20004, p. 11). Polarizirano pluralni medijski sustav predstavlja sustav na koji država ima snažniji utjecaj, više je ovisan o političkoj sferi, ima slabije razvijene komercijalne medije i slabije izražen novinarski profesionalizam, a tipičan je za mediteranske zemlje (Hallin & Mancini, 2004, p. 90). Između ova dva modela nalazi se Demokratsko korporativni sustav koji odlikuju visoko polarizirani mediji, ali i razvijeni komercijalni mediji i jače izražen novinarski profesionalizam, a tipičan je za zemlje Sjeverne Europe i Njemačku (Hallin i Mancini, 2004, p. 145).

1.3.2. Definicija javne rasprave

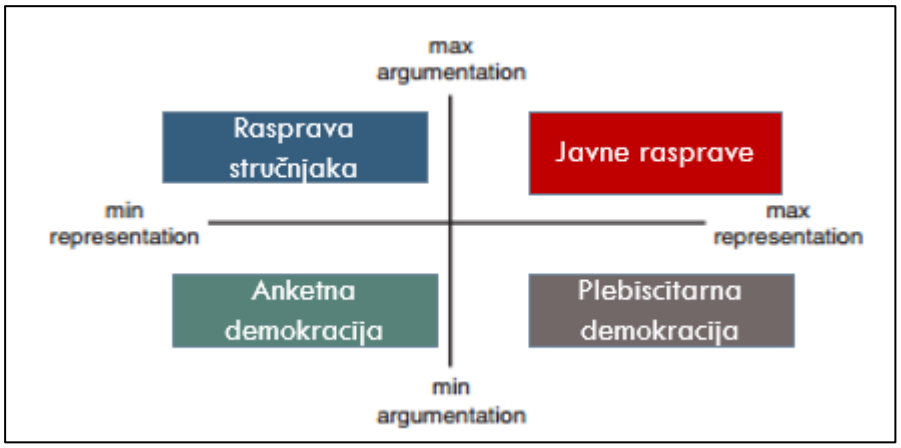
Prema dosad navedenim definicijama možemo reći da javna rasprava (eng. public deliberation) predstavlja diskurs u obliku konverzacije. Za Fishkina i Luskina (2005, p. 285) ona se odnosi na odmjeravanje suprotstavljenih mišljenja kroz diskusiju koja obuhvaća sva gledišta značajnog dijela cijele populacije i temelji se na točnim informacijama i objektivnoj stvarnosti, argumentima i protuargumentima te spremnosti sudionika da saslušaju suprotstavljena mišljenja. Kant (navedeno u Habermas, 1991, p. 118.) je nazvao javne rasprave kamenom temeljcem istine, jer sve što se proklamira kao istina testira svoju istinitost pred svakim razumnim ljudskim bićem. Javne rasprave utječu na oblikovanje mišljenja sudionika, o čemu svjedoče rezultati istraživanja u kojima su ispitanici u heterogenim skupinama argumentirano raspravljali o određenoj političkoj temi sa svojim neistomišljenicima, nakon čega je došlo do promijene mišljenja, a ne do polarizacije mišljenja (Habermas, 2006). Takvi rezultati pobuđuju opravdanu nadu u mogućnost otkrivanja istine i otkrivaju kognitivni potencijal javnih rasprava (Habermas, 2006, p. 414).

> Cilj je javnih rasprava pretvoriti volje pojedinaca u razumne odluke, i to tako da se kroz proces javnog nadmetanja privatnih argumenata postigne konsenzus oko onoga što nužno mora biti u interesu svih. (Habermas, 1991: 83.)

Habermas (2006, p. 416) javnu raspravu smatra esencijalnim elementom demokratskih procesa te izdvaja njene ključne funkcije:

a) pokretanje važnih tema, dobivanje traženih informacija i interpretacija
b) analiziranje tema pomoću argumenata „za“ i „protiv“
c) stvaranje racionalno motiviranih stavova „za“ i protiv“

Na Habermasovoj definiciji javne rasprave počiva deliberativna demokracija koju Kim et al. (1999, p. 361) opisuju kao diskurzivni sustav u kojem građani razmjenjuju informacije o javnim događajima, formiraju mišljenja, razgovaraju o politici i sudjeluju u političkim procesima. Javna rasprava može dovesti do konsenzusa, ali i poboljšati intelektualne kvalitete sudionika (Elster, 1998, p. 11, navedeno u Gonzalez – Bailon et al., 2010, p. 2). Za Winklera (2003: 8) javna je rasprava komunikacija u kojoj su „mišljenja i izjave sudionika izložene propitivanju valjanosti pred javnošću“ te obuhvaća sve procese koji prethode donošenju odluka.



Slika 2. Načini donošenja odluka (prilagođeno prema Gonzales - Bailon et al., 2010, p. 3)

Na slici 2. prikazana su četiri načina donošenja odluka koja se međusobno razlikuju s obzirom na argumentiranost i reprezentativnost komunikacija koje im prethode. Gonzales – Bailon et al. (2010, p. 3) uočavaju da javne rasprave kao načini donošenja odluka spadaju u I kvadrant (visoka argumentiranost i visoka reprezentativnost). II kvadrant predstavljaju načini donošenja odluka koji se temelje na raspravi malog broja sudionika (stručnjaka), III kvadrant predstavljaju načini donošenja odluka koji se temelje na provođenju anketa na odabranom uzorku građana, a IV kvadrant predstavlja plebiscitarnu demokraciju u kojoj građani iskazuju svoje stavove putem glasovanja.

1.3.3. Odlike javne rasprave

Na temelju istraživanja i dosad iznesenih definicija mogu se uočiti pokazatelji konverzacije koja ima odlike javne rasprave :

a) Racionalnost/ argumentiranost
b) heterogenost/reprezentativnost/ kritičnost
c) jednakost sudionika
d) usmjerenost na temu rasprave
e) interaktivnost/reciprocitet
f) sloboda sudionika
g) otvorenost sudionika

Racionalnost konverzacije odnosi se na uporabu dobrih argumenata u konverzaciji. Kada definira javnu raspravu Dryzek (2000, p. 64) naglašava upravo ovu odliku te javnu raspravu opisuje kao racionalan i logičan oblik komunikacije lišen osjećaja. Sam pojam argument Govier (2013, p 1.) definira kao niz tvrdnji, od kojih je jedna zaključak, a jedna ili više njih su premise kojima je cilj obrazložiti zaključak. Dobar argument sadrži točne premise, a zaključak logički proizlazi iz njih (Gensler, 2012, p. 55). Stromer-Galley (2007, p. 4) dobar ili racionalan argument definira kao onaj u kojem su tvrdnje utemeljene na empirijski provjerljivim dokazima ili na općeprihvaćenim načelima. S tim u vezi, ako tvrdnju nekog sudionika u konverzaciji shvatimo kao zaključak, mogli bismo kazati da takav sudionik koristi dobar argument ukoliko je kao obrazloženje svoje tvrdnje iznio barem jednu empirijski provjerljivu tvrdnju ili općeprihvaćeno načelo. Jensen (2014, p. 29), analizirajući političke online debate u Danskoj, kao dobru prihvaća i izvanjsku argumentaciju, kada se sudionik u raspravi poziva na vanjske izvore poput citata iz članaka, knjiga i slično. Idealna argumentacija pretpostavlja da sudionik u konverzaciji brani svoj stav tako da na argument odgovara protuargumentom (Weger & Aaakhus, 2003, p. 28). Ono što najčešće ne predstavlja dobar argument je „ad hominem“ argument koji se tradicionalno definira kao nebitan za diskusiju, a njime se kritizira sudionika rasprave umjesto da se kritizira tvrdnja koju je on izrekao (Kišiček, 2013). Koliko je dobra argumentiranost važna odlika javne rasprave naglašava i Habermas (1984, p. 25) kada tvrdi da rasprava isključuje svaki oblik osim sile boljeg argumenta.

Heterogenost skupine očituje se kroz izražavanje neslaganja u raspravi i postojanje različitih mišljenja. Time se izbjegava polarizacija mišljenja kakva se javlja u homogenim skupinama, a svaki sudionik u raspravi, suočen s drugačijim mišljenima, ima mogućnost kritički preispitivati vlastite stavove (Stromer – Galley, 2007, p. 5). Veća heterogenost ukazuje na veću

reprezentativnost rasprave, čime se zadovoljava jedan od kriterija prema kojem se rasprava može smatrati javnom (Gonzales – Bailon et al., 2010, p.3). Ovu karakteristiku javne rasprave Graham (2008, p. 26) naziva kritičnost.

Jednakost sudionika odnosi se na mogućnost podjednakog sudjelovanja u raspravi, čime se izbjegava dominacija jednog sudionika i osigurava da sudionici rasprave upoznaju različite stavove (Burkhalter et al., 2002, navedeno u Stromer – Galley, p. 6). Graham (2008, p. 21) uočava dvije razine jednakosti: strukturalnu i diskurzivnu. Strukturalna jednakost odnosi se na mogućnost jednakog pristupa raspravi svima, a diskurzivna na jednako uvažavanje svakog sudionika rasprave (Graham, 2008, p. 21).

Usmjerenošću na temu rasprave izbjegava se rasprava o bilo čemu što nije definirano prije početka rasprave ili nije povezano s početnom temom. Usmjerenost na temu osigurava da se u raspravi postigne što iscrpnije razmatranje teme, što je svrha same rasprave (Stromer – Galley, 2007, p. 6).

Interaktivnost rasprave odnosi se na međusobnu uključenost sudionika u raspravu, a očituje se tako da sudionici ne vode monologe (Stromer – Gallley, 2007, p. 7) nego da reagiraju i odgovaraju na pitanja, argumente ili mišljenja ostalih sudionika u raspravi, zbog čega Graham (2008, p. 20) ovu odliku rasprave naziva reciprocitet. Rafaelli (1988, p. 118) interaktivnost uočava u nizu objava u kojem je svaka kasnija objava odgovor na prethodnu, s time da se potpuna interaktivnost postiže kada odgovor nije samo reakcija na prethodnu objavu nego na sve prethodne objavu u nizu i na samu temu o kojoj se razgovara.

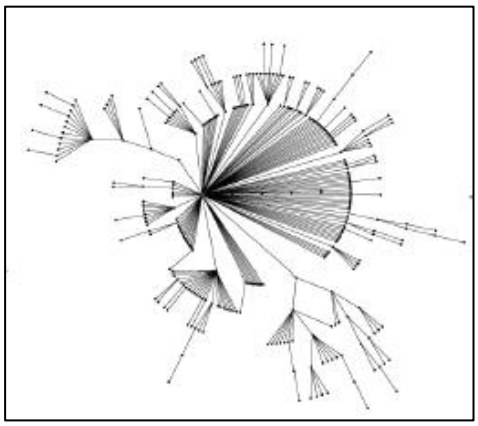
Sloboda rasprave odnosi se na mogućnost da sudionici slobodno razmjenjuju informacije, mišljenja i argumente (Graham, 2008, p. 21), bez ikakve prisile (Winkler, 2003, p. 8).

Otvorenost rasprave odnosi se na: nastojanje sudionika da sve informacije važne za raspravu budu poznate svima koji sudjeluju u njoj (Graham, 2008, p. 21); spremnost sudionika da sudjeluju u razvijanju rasprave i da uče jedni od drugih (Winkler, 2003, p. 8); spremnost sudionika da promijene mišljenje kada se suoče s dobrim argumentima (Habermas, 1991, p. 41).

1.3.4. Struktura konverzacije građana na internetu

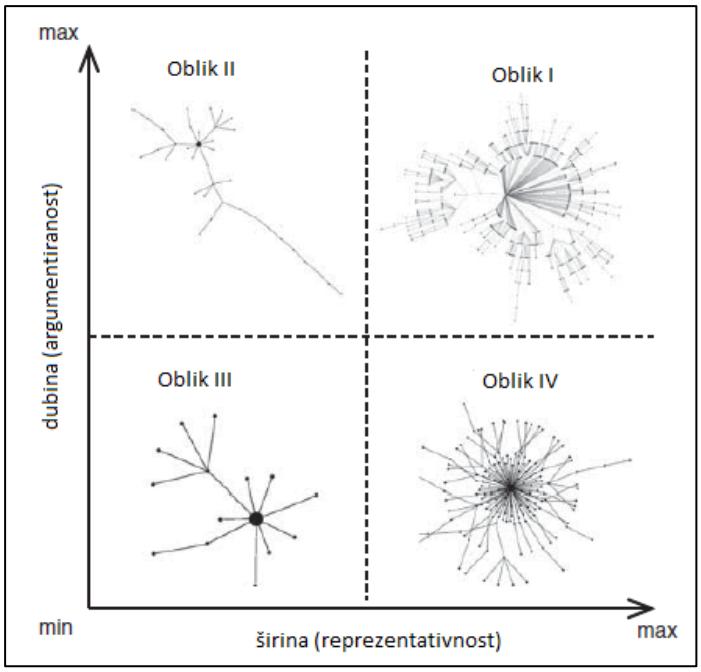
Razvidno je da priroda internetske javne sfere nudi pretpostavke za realizaciju javne rasprave, jer u njoj građani mogu slobodno razmjenjivati informacije, stvarati sadržaj i na taj način zaobići „institucionalne dostavljače informacija“ (Winkler, 2003, p. 9). Takva se

konverzacija, primjerice, odvija na Internetskim forumima koje Li et al. (2012, p. 979) definiraju kao mrežne aplikacije namijenjene vođenju konverzacija i objavljivanju sadržaja o različitim temama koje stvaraju korisnici. Gomez et al. (2008, p. 650) su proučavali karakteristike konverzacije građana kao oblika interakcije na forumu Slashdot i uočili su da se ona može prikazati pomoću radijalnog stabla.



Slika 3. Prikaz interakcije građana na Internetskom forumu Slashdot pomoću radijalnog stabla (Gomez et al., 2008, p. 651)

Na slici 3. prikazana je interakcija građana novinara tijekom konverzacije na Internetskom forumu Slashdot pomoću radijalnog stabla (Gomez et al., 2008, p. 651). Središte stabla predstavlja prvu objavu građana novinara, a svi odgovori na nju pripadaju prvom sloju konverzacije. Svi odgovori na odgovore u prvom sloju pripadaju drugom sloju konverzacije i tako redom. Interakciju građana karakterizira širina i dubina, gdje širinu predstavlja najveći broj objava u bilo kojem sloju, a dubinu najveći redni broj sloja koji se pojavi u konverzaciji (Gonzales – Bailon et al., 2010, p. 6).



Slika 4. Oblici interakcija na Internetskim forumima (Gonzales – Bailon et al., 2010, p. 7)

Slika 4. prikazuje izgled radijalnih stabala za četiri oblika interakcija koji se pojavljuju na internetskim forumima (Gonzales – Bailon et al., 2010, p. 7). Prvi je oblik onaj koji privuče velik broj sudionika i postiže veliku interaktivnost. Takav oblik karakterizira velika dubina i širina konverzacije. Drugi oblik karakterizira velika interaktivnost, ali u njoj sudjeluje svega nekoliko građana, pa je njena širina znatno manja od dubine. Treći i četvrti oblik imaju nisku interaktivnost, ali dok u trećem obliku sudjeluje svega nekoliko građana, u četvrtom sudjeluje velik broj. Ukoliko postojanje dubljih slojeva pretpostavlja učestaliju uporabu dobrih argumenata, a velik broj objava sudjelovanje većeg broja građana, Gonzales – Bailon et al. (2010, p.7) zaključuju da je širina interakcije strukturalni pokazatelj reprezentativnosti konverzacije, a dubina interakcije strukturalni pokazatelj argumentiranosti konverzacije, pa s tim u vezi drugi oblik interakcije s velikom dubinom i širinom smatraju najpogodnijim za razvijanje javnih rasprava.

Slična struktura interakcije građana može se uočiti i na novinskim portalima kada korisnici pišu komentare na objavljene članke. U tom slučaju središte radijalnog stabla predstavlja objavljeni članak, prvi sloj predstavljaju komentari na članak, drugi sloj predstavljaju odgovori na komentare u prvom sloju i tako redom.

1.3.5. Određivanje razine javne rasprave na Internetu

Bez analize sadržaja i isključivo na temelju strukture interakcije građana na Internetu ne možemo sa sigurnošću zaključiti ima li njihova konverzacija odlike javne rasprave, ali možemo uočiti strukturalne pokazatelje važnih odlika javne rasprave - reprezentativnosti i argumentiranosti konverzacije, a onda na temelju toga zaključiti kolika je razina javne rasprave. Uzimajući u obzir definicije dubine i širine interakcije građana tijekom konverzacije na internetu Gomez et al. (2008, p. 652) uvode još jedan strukturalni pokazatelj koji nam može pomoći u određivanju razine javne rasprave na Internetu. Naime, velika širina interakcije sama po sebi ne mora značiti da konverzacija ima odlike javne rasprave, jer većina odgovora na početnu objavu može biti u prvom sloju i razina interaktivnosti može biti vrlo niska, a velika dubina interakcije može se pojaviti i kada u konverzaciji sudjeluje mali broj građana. Da bi otklonili ove nedostatke i da bi pri određivanju razine javne rasprave uzeli u obzir dubinu i širinu interakcije, Gomez et al. (2008: 652) definirali su h-indeks konverzacije kao „najveći redni broj sloja **j** u kojemu ima barem **j** komentara“, gdje se pod komentarom smatra svaka objava građana u prvom ili višem sloju konverzacije. Drugim riječima, traži se najdublji sloj čiji je broj komentara jednak ili veći od njegovog rednog broja. Stoga h-indeks konverzacije uzima u obzir i dubinu i širinu interakcije građana, ali i dalje, prema Gomezu et al. (2008, p. 653), nije posve dostatan pokazatelj razine javne rasprave, pa oni predlažu da se u procjeni razine rasprave uzme u obzir i ukupan broj komentara građana u konverzaciji. Prema ovim autorima razina je rasprave veća kada se isti h-indeks pojavi u konverzaciji s manjim brojem ukupnih komentara. Predloženi pokazatelj razine rasprave nazvali su razina polemičnosti (eng. degree of controversy), a računa se prema formuli (prilagođeno prema Gomez et al., 2008, p. 653):

$$r_p = h - index \quad + \frac{1}{n_k}, \tag{1}$$

gdje je r_p razina polemičnosti, a n_k ukupan broj komentara u raspravi.

Prema definiciji polemika predstavlja „javnu, pismenu ili usmenu borbu mišljenja pri prosuđivanju o stvarima, pojavama i djelima od općeg (kulturnog, političkog itd.) ili osobnog interesa“ (Anić, 1991: 492), pa bi se prema tome polemična konverzacija trebala odnositi na onu u kojoj se pojavljuje što više oprečnih mišljenja. Prema formuli Gomeza et al.. (2008, p. 653) možemo zaključiti da razina polemičnosti raste kada se u konverzaciji postigne što dublji sloj interakcije u kojem sudjeluje što veći broj građana (visoki h-indeks) te da je između dvije

konverzacije s istim h-indeksom polemičnija ona koja ima manji ukupni broj komentara. Drugim riječima, razina polemičnosti otkriva nam prije svega razinu interaktivnosti i postojanja oprečnih mišljenja, ali u odnosu na ukupni broj komentara.

Postojanje dubljih slojeva u konverzaciji povezano je s učestalijom uporabom dobrih argumenata, a velik broj komentara u raspravi sa sudjelovanjem većeg broja građana, pa Gonzales – Bailon et al. (2010, p.7) zaključuju da je širina interakcije strukturalni pokazatelj reprezentativnosti konverzacije, a dubina interakcije strukturalni pokazatelj argumentiranosti konverzacije.

Za samu interaktivnost može se pronaći još nekoliko strukturalnih pokazatelja. Tako Graham (2008, p. 20), koji za interaktivnost koristi izraz reciprocitet i definira ga kao odliku konverzacije u kojoj sudionici slušaju druge i odgovaraju na njihove objave, za pokazatelja reciprociteta odabire ukupan broj odgovara na početnu objavu i razinu centralizacije konverzacije. Naime, veću razinu centralizacije ima ona konverzacija u kojoj dominira manji broj sudionika. Kada se konverzacija prikaže u obliku radijalnog stabla ili mreže može se uočiti da pojedini sudionici dominiraju u konverzaciji te da s njima, u odnosu na ostale, stupa u interakciju veći broj sudionika. Što je manji stupanj centralizacije, razina je kvalitete javne rasprave veća.

Osim strukturalnih pokazatelja kvalitete javne rasprave koji se dobiju određivanjem ukupnog broja odgovora na početnu objavu, određivanjem broja odgovora u pojedinom sloju konverzacije, određivanjem rednog broja najdubljeg sloja konverzacije i određivanjem razine polemičnosti, postoje i pokazatelji koji zahtijevaju prethodno analiziranje sadržaja odgovora u konverzaciji. Tako se razina racionalnosti konverzacije može izračunati određivanjem broja odgovora koji su dobro obrazloženi, a razina heterogenosti brojem odgovora u kojima se izražava neslaganje (Graham, 2008, p. 26) i sl.

1.4. Javno mnijenje

Javno mnijenje je pojam koji se često koristi i predmet je interesa političara, novinara i cjelokupne javnosti. Pomno se istražuje njegov utjecaj na politiku, medije i građane, kao i metode kojima se mjeri. Postoje brojni izvori koji nam mogu poslužiti za mjerenje javnog mnijenja, a pojava interneta učinila je dostupnim mnoštvo tekstova kojih su autori građani i koji nam mogu poslužiti za istraživanje javnog mnijenja. Javno mnijenje uključuje sentimente, pa istraživanje javnog mnijenja podrazumijeva istraživanje sentimenata izraženih u komentarima, objavama i osvrtima građana na internetu. Javno se mnijenje može iskazati pomoću brojeva

tako da se analiziranom tekstu pridruži vrijednost njegove semantičke orijentacije (SO) koja može biti pozitivan ili negativan broj, u ovisnosti o tome izražava li taj tekst pozitivan ili negativan sentiment prema onome na što se odnosi. Analiza se sentimenata može provesti ručno, kada istraživač procjenjuje jakost i predznak sentimenata riječi, izraza ili cjelokupnog teksta te automatski, kada računalni program na temelju prepoznavanja riječi i izraza u tekstu te njihova rasporeda u rečenici računa SO teksta, za što se izrađuju posebni računalni algoritmi. Ručna analiza predstavlja zlatni standard na temelju kojeg se mjeri preciznost računalnih programa za analizu sentimenata.

1.4.1. Definicije javnog mnijenja

Pojam mnijenje imao je kroz povijest više značenja, od kojih se mogu istaknuti dva osnovna: prvo se značenje odnosilo na prosudbu koja je nesigurna i još se mora dokazati, što je odgovaralo Platonovom izrazu „doxa“; a drugo se značenje odnosilo na reputaciju, tj. na ono što netko predstavlja u očima drugih (Habermas, 1991, p. 69). U 18. stoljeću, s pojavom buržujske države utemeljene na ustavu, počinje se koristiti izraz „javno mnijenje“ koji dobiva svoje današnje značenje i ulogu koju ima u političkom životu društva. Javno mnijenje stvarali su informirani građani koji su pripadali svim klasama, osim onoj najnižoj u kojoj su bile osobe koje su obavljale teške poslove, pa nisu imale vremena i mogućnosti za bavljenje političkim pitanjima (Habermas, 1991, p. 102).

Habermas (1996, p. 360) je javna mnijenja opisao kao rezultat procesa u kojima se različiti stavovi filtriraju, a potom i sintetiziraju ili, drugačije kazano, kao rezultat javnih rasprava. Štoviše, prvotna je uloga javne sfere „osigurati oblikovanje različitih javnih mnijenja nastalih kao rezultat kritičkih i razumnih javnih rasprava“ (Habermas, 2006: 416). U stvaranju javnog mnijenja, shvaćenog kao samo jednog prevladavajućeg mnijenja među svim drugim javnim mnijenjima, sudjeluju novinari, političari, posebne interesne skupine i pripadnici civilnog društva. Tanta (2007: 15) javno mnijenje definira na način da razdvaja pojmove javnost i mnijenje, pa navodi da je javnost „ skupina ljudi koja ima zajednički interes u određenom subjektu“, a mnijenje je „nedovoljno utemeljeno mišljenje u kojem su izražena stajališta o nekoj temi koja, kada postanu dovoljno snažna, vode prema verbalnim i fizičkim akcijama“. Key (1961, navedeno u Zaller, 2003: 2) javno mnijenje definira kao “mnijenja privatnih osoba za koje Vlada smatra da ih je razborito uvažiti“.

Erikson i Tedin (2015, p. 8) smatraju da javno mnijenje obuhvaća sve ono što želi populacija odraslih građana u odnosu na teme koja su važne Vladi , a sama mnijenja definiraju

kao verbalno očitovanje stavova. Kao pokazatelje javnog mnijenja, koje je potrebno razlikovati od samog javnog mnijenja, ovi autori navode: rezultate anketa kojima se ispituju stavovi građana, nemire, demonstracije i slična okupljanja građana. Razlikovanje javnog mnijenja od njegovih pokazatelja, prema Eriksonu i Tadinu (2015), nužno je zbog mogućnosti pogrešne interpretacije rezultata i zbog činjenice da mnijenja očitovana kroz okupljanja građana ne predstavljaju stavove cjelokupne populacije, već samo njezinog određenog dijela.

U definiranju koncepta javnog mnijenja mogu se uočiti dva smjera: jedan koji javno mnijenje promatra kao rezultat razumnih i kritičkih rasprava aktivnih građana te drugi u kojem aktivne građane zamjenjuju parlamentarne stranke, pa tako rezultat parlamentarnih rasprava predstavlja javno mnijenje koje Vladi daje legitimitet za donošenje odluka (Habermas, 1991, p. 238).

1.4.2. Uloga javnog mnijenja u javnoj sferi

Krippendordf (2005, p. 129) uočava da u suvremenom društvu javno mnijenje postaje izuzetno moćan sudionik političke javne sfere, ili, kako Kuhnen i Niessen (2010, p. 29) tvrde, ono može poslužiti kao mehanizam vladanja. Guizot (navedeno u Habermas, 1991, p. 101.) vladavinu javnog mnijenja pripisuje onim društvenim sustavima koji sve svoje građane prisiljavaju da stalno tragaju za istinom i pravdom, tako da ono što je istinito i pravedno regulira ponašanje aktualne vlasti. Sustavi koji imaju zastupnike u parlamentima, prema mišljenju Guizota, imaju upravo takvu odliku, i to zahvaljujući:

a) raspravama koje prisiljavaju aktualnu vlast da traga za zajedničkom istinom
b) uvidom javnosti u rad vlasti tijekom traganja za zajedničkom istinom
c) slobodom novinarstva koja potiče građane da i sami tragaju za istinom i da na nju ukazuju vlastima

Za političke elite i za samu javnost sustav glasovanja u periodičkim izborima čini javno mnijenje važnim sudionikom političke javne sfere (Gerhard, 1993, p. 26, navedeno u Habermas, 2006, p. 418). Javna mnijenja imaju utjecaj na sam centar političke javne sfere, tj. na Vlade, ali isto tako njihov se utjecaj širi i u suprotnom smjeru - na javnost iz koje su nastala. Vlada i javnost mogu zauzeti pozitivan, negativan ili indiferentan stav prema javnom mnijenju te ponovno razmotriti svoje stavove. Na taj način politička komunikacija u javnoj sferi služi kao filter kroz koji prolaze različita javna mnijenja, a preostaju samo ona koja su rezultat kritičkih rasprava i kao takva predstavljaju okvir za donošenje legitimnih političkih odluka (Habermas, 2006, pp. 417 - 418). Takvu su povezanost potvrdili Page i Shapiro (1983, pp. 186-187) kada

su u razdoblju između 1935. i 1979., na temelju usporedbe rezultata istraživanja javnog mnijenja i promjene politike u SAD-u, zaključili da promjena javnog mnijenja može značajno utjecati na promjenu politike, ali i da politika, premda u manjoj mjeri, može utjecati na promjenu javnog mnijenja.

Da bi se u javnoj sferi stvorila javna mnijenja koja su rezultat kritičkih javnih rasprava, potrebno je uspostaviti jasna „pravila igre“, a preduvjeti za nastajanje takvih pravila su (Habermas, 2006, p. 420):

a) neovisni medijski sustav koji djeluje prema vlastitim pravilima i kao takav omogućuje političku komunikaciju između političkog centra i civilnog društva
b) snažno civilno društvo koje potiče građane na sudjelovanje u raspravama

Dakako, ovdje je uloga javnog mnijenja opisana prema teoretskom modelu, pa treba uzeti u obzir da struktura moći kakva postoji u javnoj sferi umnogome u praksi može poremetiti sustav komunikacije i filtriranje javnih mnijenja koji su rezultat kritičkih rasprava (Habermas, 2006, p. 418). Neinformiranost građana o nekoj temi i nesudjelovanje u raspravama osnažuje pozicije izabranih političkih elita zbog povećane mogućnosti manipulacije i filtriranja informacija (Fishkin et al., 2000, p. 659). Političari i interesne skupine mogu laganjem i obmanjivanjem javnosti utjecati na javno mnijenje, a onda na temelju izmanipuliranog javnog mnijenja donositi odluke, zbog čega se takva praksa ne može smatrati demokratskom. Pa čak i kada putem edukacije i uvjeravanja, koristeći dobre argumente, izvršitelji vlasti utječu na javno mnijenje, takva se praksa ne može smatrati „čistom“ demokratskom (Page i Shapiro, 1983, p. 189).

1.4.3. Istraživanja javnog mnijenja

S jedne strane, u literaturi prevladava definiranje javnog mnijenja kao zbira individualnih odgovora ispitanika u anketama, čime se anketama daje suveren status u istraživanjima javnog mnijenja nakon II svjetskog rata (Manza & Cook, 2002, p. 631). S druge pak strane, treba uzeti u obzir i činjenicu da postoje i druge metode, budući da se javno mnijenje kroz povijest izražavalo na različite načine, pa tako i na

> javnim okupljanjima, u salonima, kafićima, preko uličnih nemira, peticija, štrajkova, pisama poslanih urednicima novina i političkim elitama, društvenih pokreta, te pomoću dubinskih intervjua, deliberativnih anketa i ostalih oblika izražavanja osobnih sentimenata (Manza & Cook, 2002: 632).

Entman i Herbst (2001, pp. 206 - 209) zaključili su da način utvrđivanja javnog mnijenja ovisi o vrsti javnog mnijenja i da postoje:

a) aktivno javno mnijenje
b) masovno javno mnijenje
c) latentno javno mnijenje
d) percipirano javno mnijenje

Aktivno javno mnijenje predstavlja zbir stavova sudionika javne sfere koji aktivno sudjeluju u civilnom društvu i politici. Formira ga manji broj građana koji imaju čvrste stavove i nisu podložni manipulaciji (Entman & Herbst, 2001, p. 207).

Masovno javno mnijenje određuje se pomoću anketa i predstavlja zbir stavova svih građana koji pri tom ne moraju biti dobro informirani o temi koja je predmet javnog mnijenja. Stoga je ovo mnijenje podložno manipulaciji i može se kazati da je pod utjecajem medija, Vlade, događanja i sastavljača anketa (Entman & Herbst, 2001, pp. 207 - 211).

Key (1961, p. 262, navedeno u Zaller, 2003, p. 2) uočava da postoji i latentno javno mnijenje i smatra da ono najviše zanima političare, jer se odnosi na stavove građane koji će se u budućnosti, u vrijeme izbora, formirati kao odgovor na neko političko djelovanje. Ovo mnijenje uključuje i temeljna uvjerenja te sustav vrjednota birača, pa ga političari ne mogu utvrditi jednostavno pomoću običnih anketa, već kombinacijom različitih metoda: anketama, razgovorom s kolegama, na temelju iskustva u politici i instinktom – osjećajem za sklonosti svog biračkog tijela (Entman & Herbst, 2001, str. 208).

Percipirano javno mnijenje odnosi se na pretpostavljene stavove građana - one za koje se vjeruje da postoje, a osnažuje se putem medija (Entman & Herbst, 2001, str. 207). Takvo bi se javno mnijenje moglo utvrditi analizom novinskih sadržaja, što su i učinili Kuhnen i Niessen (2010) kada su pomoću računalnog programa brojčano određivali negativnost ili pozitivnost novinskih članaka u odnosu na temu o kojoj se formiralo javno mnijenje. Za tu vrstu javnog mnijenja upotrijebili su izraz „široko rasprostanjeno mnijenje“ (eng. widespread opinion).

U SAD-u je izvršeno mnoštvo kvantitativnih istraživanja kojima je cilj bio utvrđivanje utjecaja javnog mnijenja na politiku ili mjerenje odaziva (eng. ressponsiveness) politike na javno mnijenje. Rezultati takvih istraživanja pokazali su povezanost javnog mnijenja i politike, što je postalo jedan od vodećih argumenata zagovornika teorija velikog utjecaja javnog mnijenja na politiku (Manza & Cook, 2002, p. 632). Istraživanja su pokazala da čitatelji tiskanih novina pokazuju veći stupanj angažiranosti u civilnom društvu i općenito u političkom angažmanu, kao i građani koji se služe internetom, tj. e-građani (Hoffman, 2006, p. 69.). Nadalje, online korisnici koji tragaju za informacijama i razmjenjuju e-mailove aktivniji su u

civilnom društvu nego li oni koji igraju igrice ili samo sudjeluju u sobama za razgovore. Iako nijedno empirijsko istraživanje izravno ne povezuje internet i sudjelovanje u politici ipak se može pretpostaviti takva povezanost i zbog toga zaključiti da veća uporaba online informacija potiče veće uključivanje u politiku (Hoffman, 2006, p. 60), budući da se političko sudjelovanje potiče kroz različite oblike komunikacije.

1.4.4. Dubinsko istraživanje mnijenja na internetu

Riječi su sredstvo za dijagnostiku mentalnog, društvenog i fizičkog stanja osobe koja ih uporablja (Pennebaker et al., 2003, p. 548). Njima se, između ostalog, izražavaju i sentimenti koje Boiy et al. (2007, p. 350) definiraju kao prosudbe i ideje koje su uvjetovane ili obojane emocijama. Svojstvo je sentimenata subjektivnost, jer su usko povezane s emocijama, a emocije su, kako navodi Liu (2012, p. 28), subjektivni osjećaji i misli.

Nagli rast internetske javne sfere učinio je dostupnim ogromnu količinu teksta koja može poslužiti za proučavanje sentimenata korisnika interneta (Liu, 2012, p. 5). Zbog toga se ubrzano razvija nova znanstvena tehnika - analiza sentimenata (eng. sentiment analysis) za koju se koristi i naziv - dubinsko istraživanje mnijenja (eng. opinion mining), premda izrazi sentiment i mnijenje nemaju isto značenje. Naime, Liu (2012, p. 19) mnijenje definira kao širi pojam od sentimenta i uočava da mnijenje karakterizira pet elementa: entitet, aspekt entiteta, sentiment, nositelj sentimenta i vrijeme kada je sentiment izražen, gdje je entitet objekt na koji se odnosi sentiment i može biti: proizvod, usluga, osoba, tema ili događaj. Moglo bi se reći da je emocija najuži pojam i izražena je u sentimentu kao širem pojmu, a najširi je pojam mnijenje koje je definirano sa: sentimentom, osobom koja izražava sentiment, entitetom, aspektom entiteta te vremenom kada je sentiment izražen. Stoga će Liu (2012, p. 21) kazati da je cilj dubinskog istraživanja mnijenja u nekom tekstu otkriti svih pet elemenata mnijenja: entitete i njegove aspekte na koje se sentimenti odnose, što pretpostavlja prethodno uočavanje: kategorija aspekata entiteta, sentimenata, osoba koje izražavaju sentimente i predstavljaju nositelje sentimenata te vrijeme izražavanja sentimenata.

Analiza sentimenata može se provesti ručno, kada istraživač pronalazi i označava dio teksta koji izražava sentiment, ili automatski, kada se tekst koji izražava sentiment pronalazi i označava pomoću računalnog programa. Tekst koji izražava sentiment označava se kao pozitivan, negativan ili neutralan. Ručna analiza je preciznija, pogotovo kad se sentiment izražava pomoću ironije i kad je važno odrediti kontekst u kojem je tekst napisan, ali zahtijeva puno više vremena, pa se stoga sve više usavršuju tehnike automatske analize sentimenata koje

u kratkom vremenu mogu obraditi velike količine teksta kakve nalazimo na internetu (Caliandro & Gandini, 2016, p. 198). Jedan pristup automatskoj analizi zasniva se na detektiranju riječi i izraza koji izražavaju sentimente u tekstu, a nalaze se u već izrađenom rječniku (eng. dictionary – based sentiment analysis) u kojem su riječi i izrazi koji izražavaju sentimente označeni kao pozitivni, negativni ili neutralni; a drugi se pristup, koji se pokazao učinkovitijim, zasniva na strojnom učenju (eng. machine - learning sentiment analysis) tako da se na temelju teksta koji je već ručno označio istraživač izrađuje računalni program koji oponaša proces ručnog označavanja (Zamith & Lewis, 2015, navedeno u Caliandro & Gandini, 2016, p. 198).

1.4.5. Semantička orijentacija (SO) teksta

Za analizu sentimenata u tekstu ključno je uočiti da informacije koje tekst sadrži mogu biti:

a) fizičke (objektivne)
b) semantičke (subjektivne)

Fizička je informacija po svojoj prirodi objektivna i ona se odnosi na ono što uistinu čujemo i vidimo, poput slova u nekoj riječi, rasporeda riječi u rečenici i sl., a semantička se informacija dobiva interpretiranjem fizičkih informacija (Diamant, 2012, p. 7). Semantika (eng. semantics) se odnosi na „ ono što komuniciramo sa svojom vrstom uporabom jezika koji je alat te komunikacije“ (Diamant, 2012: 1). Izraz „semantička informacija“ prvi su put upotrijebili Yehoshua Bar-Hillel i Rudolf Carnap (1952, navedeno u Diamant, 2012, p. 2) misleći pri tom na informaciju koja se stvara u glavi promatrača (Diamant, 2012, p. 5) I samo se ljudsko znanje može shvatiti kao semantička informacija koju smo dobili iz izvanjskog svijeta i pohranili u memoriju (Diamant, 2012, p. 7). Za semantiku je očigledno ključno značenje, pa se može reći da se ona bavi značenjima i odgovara na sljedeća pitanja (Beaver i Freeze, 2011, p. 1):

a) Na što se odnose značenja?
b) Kako se značenja pridružuju riječima, izrazima i rečenicama prirodnog i formalnog jezika?
c) Kako se značenja mogu kombinirati i upotrijebiti za zaključivanje i razmišljanje?

U svjetlu dosadašnjih definicija pojma sentiment možemo reći da jakost i vrsta sentimenta izraženog u nekom tekstu predstavlja semantičku informaciju. Kada se izrazi pomoću pozitivnih ili negativnih brojeva ta se semantička informacija naziva semantička orijentacija (eng. semantic orientation) i označava skraćenicom SO. Semantička orijentacija

teksta dobiva se zbrajanjem SO riječi u tekstu koje su nositelji sentimenata, a određivanje SO pojedine riječi svodi se na određivanje polariteta (pozitivnog ili negativnog) i jakosti sentimenta koji riječ izražava, s tim da se negativni polaritet pridaje riječima koje izražavaju negativan sentiment, a pozitivan polaritet riječima koje izražavaju pozitivan sentiment (Xu et al., 2012, p. 279). Određivanje SO teksta temelj je na kojem se izrađuju različiti računalni programi za automatsku analizu sentimenta u tekstu na internetu. Hatzivassiloglou i McKeown (1997, p. 175) u svom su istraživanju pokazali da je utvrđivanje polariteta riječi - u njihovom slučaju pridjeva - pouzdano kada ga provodi čovjek, jer je pri određivanju polariteta za isti skup pridjeva utvrđeno veliko slaganje između različitih osoba koje su označavale pridjeve kao pozitivne ili negativne s obzirom na ono što su pridjevi opisivali. Izazov je izraditi računalne programe koji će na temelju različitih fizičkih informacija u tekstu - vrste veznika između riječi poznate SO, rasporeda riječi ili udaljenosti riječi poznate SO od riječi koja označava objekt na koji se sentiment odnosi - izračunati ukupnu SO teksta, tj. polaritet i jakost sentimenta koji izražava. Tako su Ding et al. (2008) određivali SO mnijenja izraženog u osvrtima na proizvode (eng. reviews of products) na internetu. Prema njihovoj metodi računalni algoritam prepoznavao je riječi i izraze koji izražavaju sentimente (eng. opinion words i phrases), kao i niz riječi s prenesenim značenjem koji izražavaju sentimente (eng. opinion idioms), a bili su unaprijed navedeni u leksikonu s riječima, izrazima i idiomima - nositeljima sentimenata. Riječima, izrazima i idiomima u rečenici koja je izražavala osvrt na proizvod pridruživale su se vrijednosti +1 (za pozitivan sentiment) ili -1 (za negativan sentiment), ukoliko su se nalazile odmah uz riječ koja je označavala karakteristiku proizvoda, a ako su bile udaljenije jakost njihove SO je slabila. Naposljetku, ukupna SO analizirane rečenice dobivala se zbrajanjem SO pojedinih riječi koje su izražavale sentimente.

Dosad opisana metoda dubinskog istraživanja mnijenja pomoću određivanja SO teksta može se primijeniti i na komentare građana o političarima na internetu. Naime, Park et al. (2011) uočili su da komentari građana na internetu o političarima mogu biti: pozitivni, negativni i nejasni. Pozitivni komentari sadrže pozitivne sentimente i iskazuju se, primjerice, kroz pohvale i izraženi optimizam prema određenoj politici, a negativni sadrže negativne sentimente i iskazuju se kroz ismijavanje i kriticizam. Nejasni su oni komentari kod kojih nije moguće utvrditi sadrže li pozitivne ili negativne sentimente, a iskazuju se, primjerice, kroz predlaganje alternativne politike.

Automatsko računanje ukupne SO rečenice koja izražava sentimente prema nekom političaru može se, prilagodbom formule koju su upotrijebili Ding et al. (2008), izvršiti prema formuli:

$$SO\ (političar) = \sum_i^n \frac{SO\ (w_i\ )}{d\ (w_i, oznaka\ političara)}, \quad (2)$$

gdje SO (političar) označava ukupnu SO rečenice s obzirom na izražene sentimente prema političaru; n predstavlja broj nositelja sentimenta u rečenici; SO (w_i) SO nositelja sentimenta, navedenog u unaprijed definiranom leksikonu; d predstavlja udaljenost nositelja sentimenta od riječi koja označava političara. Ding et al. (2008) u svoju su formulu uvrstili udaljenost kao fizičku informaciju pomoću koje smanjuju pogrešku programa koja nastaje kada program uvrsti u izračun ukupne SO s obzirom na neki entitet nositelje sentimenta koji se zapravo ne odnose na taj entitet (karakteristiku proizvoda), jer su pretpostavili da je veća vjerojatnost da se automatski označen nositelj sentimenta (riječ, izraz ili idiom) uistinu odnosi na taj entitet kada je bliže oznaci tog entiteta. U ručnoj analizi nema potrebe za takvom intervencijom, pa se može predložiti jednostavna formula za određivanje SO teksta u kojem je izraženo mnijenje o nekom političaru:

$$SO\ (političar) = \sum_i^n SO\ (w_i\ ), \quad (3)$$

gdje je SO (političar) ukupna semantička orijentacija teksta s obzirom na izražene sentimente o političaru; n predstavlja ukupni broj riječi, izraza i idioma koji izražavaju sentimente o nekom političaru; a SO (wi) semantička orijentacija riječi, izraza i idioma koji izražavaju sentimente.

1.5. Dosadašnja istraživanja

1.5.1. Konverzacija na Internetu

Richardson i Stanyer (2011) istraživali su komentare građana na britanskim mrežnim mjestima, od kojih su neki pripadali vodećim novinskim kućama, a drugi tabloidima. Uočili su da unatoč povećanoj mogućnosti odgovaranja na komentare drugih posjetitelja i činjenici da milijuni građana mjesečno posjećuju takva mrežna mjesta tek mali postotak posjetitelja portala piše komentare. Nadalje, posjetitelji mrežnih mjesta vodećih novinskih kuća češće su pisali komentare na članke nego oni na mrežnim mjestima tabloida, a komentari su se češće ostavljali na članke vezane uz kriminal, zakon, red i religiju nego li uz druge teme iz područja zabave i sporta. Analizom sadržaja komentara zaključili su da posjetitelji nisu bili voljni mijenjati svoja mnijenja suočeni s oprečnim mnijenjima te da su korisnici mrežnih mjesta vodećih novinskih

kuća češće stupali u komunikaciju jedni s drugima (33 % posto komentara predstavljalo je odgovor na komentare drugih korisnika) nego li korisnici mrežnih mjesta tabloida (3% komentara predstavljalo je odgovor na komentare drugih korisnika) te da su u komunikaciji dominirali argumenti „ad hominem". Naposljetku su zaključila da „ u stvarnosti nema dovoljno razloga za optimizam kada je riječ o potencijalu ovakvih mrežnih mjesta za postizanje otvorene, deliberativne, diksurzivne razmjene" (Richardson & Stanyer, 2011: 19).

Ruiz et al. (2011) analizirali su komentare građana na novinskim portalima iz različitih država i uočili da se međusobno razlikuju prema: heterogenosti skupine koja sudjeluje u konverzaciji, argumentiranosti konverzacije i interaktivnosti konverzacije. Prvi model konverzacije prepoznali su kao Liberalni i uočen je na američkom portalu New York Times i britanskom Guardian, a drugi kao Polarizirano pluralni (eng. Polarized Pluralist) i uočen je na francuskom portalu LeMonde, španjolskom ElPaís i talijanskom Repubblica Odlika konverzacije u Liberalnom modelu bila je bliža opisu javne rasprave, jer su uočeni: nešto veća heterogenost mnijenja izraženih u konverzaciji (11, 95% -23, 85% komentara izražavalo je neslaganje s većinskim mnijenjem), veće toleriranje manjinskih oprečnih mnijenja, veća razina argumentiranosti (65,6 % - 78,9%) i veća razina međusobnog uvažavanja sudionika u konverzaciji. U drugom je modelu uz manju heterogenost mnijenja i slabiju argumentiranost (42,5 % - 58,1%) uočena i veća polarizacija mnijenja tijekom konverzacije (manje od 3 % komentara je izražavalo neslaganje s većinskim mnijenjem). Na svim je istraživanim portalima većina posjetitelja dijelila ista mnijenja, što se može objasniti činjenicom da građani u pluralnom medijskom okružju biraju one portale na kojima se izražavaju mnijenja koja su njima bliska, što dodatno pojačava političku polarizaciju društva. Ruiz et al. (2011, p. 484) zaključili su da kulturalni kontekst utječe na kvalitetu konverzacije građana na novinskim portalima i da unatoč uočenim razlikama u kvaliteti konverzacije na svim istraživanim portalima pisanje komentara uglavnom predstavlja „prostor za reproduciranje homogenih mnijenja i izražavanje frustracija građana", ali i da postoji manji dio građana koji sudjeluje u razumnim i argumentiranim konverzacijama, što je učestalije na novinskim portalima iz prvog modela.

Milioni et al. (2012, p. 38) proveli su analizu sadržaja komentara na grčkim novinskim portalima i ustvrdili da mnijenja izražena u komentarima nisu dovoljno različita i da je na svim portalima više od 70 % komentara izražavalo isto mnijenje.

Istražujući sedam katalonskih novinskih portala Noci et al. (2012) došli su do zaključka da ovakva mrežna mjesta uopće ne poboljšavaju kvalitetu konverzacije na internetu i da je konverzacija građana daleko od one koja se očekuje u Habermasovom modelu javne sfere. Osim što je većina građana novinara u uzorku koji su oni analizirali ostavila samo jedan

komentar (83, 65%), što upućuje na zaključak o maloj interaktivnosti konverzacije, njihovi su rezultati pokazali i da većina građana novinara (82%) uopće ne traži pojašnjenje tuđeg stava, da većina građana novinara (64%) ne iskazuje nikakav interes za tuđa obrazloženja, a preostali ga jedva iskazuju te da 82 % građana novinara ne prihvaća nikada tuđe argumente, a preostali ih uglavnom ne prihvaćaju.

Analizirajući konverzaciju građana o klimatskim promjenama na britanskom novinskom portalu Guardian, i to uz samo jedan novinski članak koji je imao najveći broj komentara (1697), Collins i Nerlich (2015, p. 198) uočili su da je većina sudionika napisala samo jedan komentar (65%) te da je udio komentara koji su predstavljali odgovor na prethodni iznosio 70 %. Dva su građanina novinara napisala 10 % svih komentara, a šest je napisalo više od petine svih komentara. Dominacija manjeg broja sudionika takvu konverzaciju čini centraliziranom, zbog čega se ne može reći da ona ima odlike javne rasprave, ali zato konverzacija izrazito angažiranih građana novinara, kako su uočili Collins i Nerlich (2015, p. 205), ima takve odlike. Naime, njihova analiza tzv. „ključnih komentara" u kojima su izneseni svi aspekti teme koja je bila predmet konverzacije i kojima su autori bili izrazito angažirani građani novinari, pokazala je da je konverzacija građana novinara bila dobro argumentirana.

Interaktivnost konverzacije građana novinara značajno se razlikuje od portala do portala. Tako su Godde et al. (2016) istraživali konverzaciju građana na 6 njemačkih novinskih portala određujući broj komentara koji predstavljaju odgovore na prethodne komentare. Izračunali su da je na novinskom portalu Zeit bilo gotovo 60 % komentara koji su bili odgovor na prethodne, dok je na novinskom portalu Focus bilo otprilike samo 10 % takvih komentara. Uočena je i razlika u heterogenosti izraženih mnijenja koja se mjerila pomoću broja građana novinara koji sudjeluju u konverzaciji. Tako je na novinskom portalu Bild komentare na otprilike 75 % članaka napisalo 10 građana novinara, dok je na novinskom portalu Zeit sličan postotak članaka komentiralo 50 građana novinara.

Povoljniju sliku o konverzaciji građana na Internetu dobili su Manosevitch i Walker (2009) u pilot istraživanju na dva američka lokalna novinska portala Des Moines Register i Scripps Treasure Coast. Njihov je uzorak obuhvatio devet konverzacija o različitim temama s ukupno 124 komentara napisanih u jednom tjednu. Polovica komentara u uzorku sadržavala je provjerljive činjenice, 40 % komentara sadržavalo je obrazloženje, 20 % komentara imalo je izvanjsku argumentaciju, 10 % komentara izražavalo je opće prihvaćena načela, a 50 % komentara predstavljalo je odgovor na komentare. Naposljetku su zaključili da komentari građana novinara imaju potencijal za stvaranje javne rasprave.

Nedostatak racionalne argumentiranosti nije samo odlika komentara građana novinara na portalima velikih nacionalnih novinskih kuća, već se može uočiti i na drugim mrežnim mjestima. Primjerice, Park i Cardie (2014) proučavali su konverzaciju građana na mrežnom mjestu Regulation Room kojeg su pokrenule vladine agencije u SAD-u upravo radi poticanja izražavanja mnijenja građana o političkim temama. Analizirali su 1047 komentara građana koji su sadržavali 9476 jednostavnih rečenica i ustanovili da otprilike 70 % tih rečenica nisu predstavljale objektivne tvrdnje. Objektivnom su smatrali onu tvrdnju koja nije pod utjecajem osobnih osjećaja, predrasuda i interpretacija, već sadrži provjerljive točne činjenice ili izražava osobna iskustva i stanja građana, što su nazvali anegdotalnim dokazima (Park i Cardie, 2014, str. 31 – 32). Weger i Aaakhus (2003, pp. 27 - 28) uočili su da konverzacija građana u AOL sobama za razgovore (eng. chat rooms) nema dovoljne odlike kvalitetne javne rasprave, što se očituje u nedostatku usmjerenosti na temu i nedovoljnoj uporabi argumenata, čemu je uzrok i neprikladno sučelje soba za razgovore koje građanima ne daju dobar uvid u tijek konverzacije i ograničava im maksimalan broj uporabljenih znakova u jednoj objavi. S obzirom na razinu polemičnosti, kao predloženi strukturalni pokazatelj interaktivnosti i argumentiranosti konverzacije, Gomez et al. (2008, p. 654) izračunali su da je u konverzacijama oko nekih tema na forumu Slash.dot razina polemičnosti postigla maksimalni iznos 11, 002, što znači da je h - indeks najpolemičnije konverzacije iznosio 11, tj. da je u konverzaciji postignuta dubina sloja 11 u kojem je bilo barem 11 komentara. Jansen (2014) je provela longitudinalno istraživanje na najvećem danskom političkom forumu Dk.politik uspoređujući odlike konverzacije građana 2001. i deset godina kasnije. Primijetila je da se postotak komentara koji su bili argumentirani provjerljivim činjenicama i izvanjskim izvorima smanjio s 13 % na 4 % te da se udio komentara koji uopće nisu bili obrazloženi povećao s 18 %na 57 %. Reciprocitet se nešto povećao s 45 % na 64 %.

Osim racionalne argumentiranosti i velike interaktivnosti, konverzacija koja ima odlike javne rasprave pretpostavlja i međusobno poštivanje sudionika. Jensen (2014) je tako u svom longitudinalnom istraživanju na danskom forumu Dk.politik uočila da je pola komentara u obje analizirane godine napisala mala skupina sudionika koja se intenzivno svađala i vrijeđala. Stoga je zaključila da razvoj novih tehnologija i poboljšane vještine sudionika nisu unaprijedile razinu rasprave na ovom forumu. Erjavec i Poler-Kovačič (2013) proveli su analizu sadržaja komentara građana s uvredljivim sadržajima na devet najviše posjećenih slovenskih novinskih portala tijekom tri mjeseca u 2013. Uočili su da umjesto kritike argumenata iznesenih u članku građani novinari vrijeđaju autore, a uvrede se mogu svrstati u nekoliko kategorija: napad na ljudsko dostojanstvo koji se izražava riječima “bolestan”, “glup”, “nepošten”, “neobrazovan” i

sl.; napad koji se temelji na pretpostavci da je autor članka pristran jer pripada određenoj društvenoj manjini, jer je žena, pripada određenoj nacionalnoj manjini ili zagovara njene interese; napadi koji se temelje na pretpostavci da je autor članka određene političke orijentacije; napadi koji se temelje na pretpostavci da je novinska kuća koja je objavila članak određene političke orijentacije. Milioni (2012, p. 42) je u svom istraživanju uočio da komentari koji se odnose na druge građane često imaju uvredljiv ton i predstavljaju govor mržnje, pogotovo kad se izražavaju u konverzaciji o osjetljivim temama. Ruiz et al. (2011, p. 477) su analizirajući portale vodećih novinskih kuća u SAD-u, Velikoj Britaniji, Španjolskoj, Francuskoj i Italiji utvrdili su da se postotak komentara u kojima građani ponižavaju jedni druge značajno razlikuje od portala do portala. Tako je najmanji postotak ponižavajućih komentara zabilježen na britanskom portalu Quardian (2,38%), a najveći na francuskom LeMonde (42,64 %).

Papacharissi (2004) je analizirao 20 konverzacija građana o političkim temama na temelju 268 komentara napisanih na forumu Usenet i utvrdio da je 14% komentara bilo necivilizirano, a 22 % nepristojno te da ih je većina predstavljala odgovore na prethodne komentare. U istraživanju je Papacharissi civiliziranost (eng. civility) definirao kao širi pojam od pristojnosti (eng. politeness) i kao odliku konverzacije u kojoj se poštuju demokratska načela i prava drugih osoba te koja pospješuje demokratsku konverzaciju. Kao necivilizirani komentari ocijenjeni su oni u kojima se poziva na nasilno rušenje demokracije, drugima oduzima pravo na slobodno izražavanje te etiketira osobe prema pripadanju određenoj političkoj skupini. Nepristojni komentari odnosili su se na one kojima se druge vrijeđa izrugivanjem, uporabom vulgarnih riječi i sl. Trećina neciviliziranih komentara odnosila se na sudionike konverzacije, a preostale dvije trećine na političare ili etničke skupine. Neljubaznost su građani očitovali najčešće kroz sarkazam, a četvrtina nepristojnih komentara izražena je uporabom vulgarnih riječi. Nepristojni su se komentari uglavnom odnosili na sudionike konverzacije. Papacharissi (2004, p. 276) je uočio da konverzacija može biti puna emocija, s nepristojnim komentarima, ali ne mora nužno biti necivilizirana te da neljubaznost i neciviliziranost ne dominiraju konverzacijama građana o politici. Do sličnog su zaključka došli i Weger i Aakhus (2003, p. 32) koji su uočili da učestalo međusobno vrijeđanje sudionika, unatoč uvriježenom shvaćanju kako takva praksa smanjuje kvalitetu konverzacije, može i pozitivno doprinijeti kvaliteti konverzacije budući da sudionike potiče na uporabu dobrih argumenata u obrani svog stava.

1.5.2. Analiza sentimenata

Analiza sentimenata komentara građana novinara na internetu može poslužiti za: istraživanje javnog mnijenja o različitim temama (Abdulla et al., 2014; Park & Cardie, 2014; Ruiz et al., 2011; Noci et al., 2012; Milioni, 2012; Papacharissi, 2004; Jensen, 2014; Erjavec & & Poler-Kovačič, 2013); istraživanje javnog mnijenja o političarima u predizbornim kampanjama (Tumitan & Becker, 2013); dobivanje povratnih informacija o kvaliteti proizvoda koji se prodaju putem interneta (Ding et al., 2008) te upoznavanje profila građana novinara (Shumueli et al., 2012; Meguebli et al., 2014).

Meguebli et al. (2014) predložili su metodologiju za određivanje političke orijentacije građana novinara na temelju analize sentimenata izraženih u njihovim komentarima na novinskim portalima. Rad je ovih autora bio usmjeren na procjenu uspješnosti računalnog algoritma za automatsku analizu sentimenata, a ne na same rezultate o političkoj orijentaciji građana novinara. Rezultate su dobivene ručnom analizom, koja predstavlja zlatni standard, uspoređivali s onima dobivenim automatskom analizom. U eksperiment su uključili 500 građana novinara - 290 na američkom portalu CNN i 210 na egipatskom Aljazeera. S namjerom da definiraju politički profil nekog građanina novinara prikupili su sva mnijenja koja je on izrazio u razdoblju od listopada 2009. do rujna 2013. Mnijenja su analizirali tako da su uočili sve teme o kojima se izjasnio taj građanin novinar, a zatim su za svaku temu uočili izražen sentiment. Naposljetku je svaki građanin novinar bio opisan nizom tema o kojima se izjasnio i nizom pripadajućih sentimenata. Analiziranje sentimenata provelo je ručno pet studenata, tako da su analizirali sve rečenice građanina novinara i u njima, na temelju prije izrađenog leksikona, uočili izraze koji su izražavali pozitivne, negativne ili neutralne sentimente o nekoj temi. Prebrojavali su pozitivne i negativne izraze u rečenici, pa su rečenicu označavali kao pozitivnu, ukoliko je bio veći broj pozitivnih izraza, ili kao negativnu, ukoliko je u njoj bio veći broj negativnih izraza. Političku orijentaciju građanina novinara identificirali su pomoću niza tema i njima pripadajućeg niza sentimenata. Primjerice, jedna od tema bila je pravo na abortus, pa su liberali imali pozitivne sentimente o toj temi, a republikanci negativne. Na temelju liste mnijenja svaki je građanin novinar označen kao: demokrat ili republikanac, ukoliko je bila riječ o posjetitelju novinskog portala CNN te sekularist ili islamist, ukoliko je bila riječ o posjetitelju egipatskog portala.

Tumitan i Becker (2013) proveli su automatsku analizu sentimenata komentara građana na brazilskom novinskom portalu Folha de São Paulo napisanih tijekom predizborne kampanje prije prvog izbornog kruga za gradonačelnika São Paula. Analizirali su 36 108 komentara na

583 novinska članka, a u analizu su uključili članke koji su se odnosili samo na tri vodeća kandidata. Iz komentara su automatski odabrali 9758 rečenica u kojima su se spominjali kandidati, a zatim pristupili automatskoj analizi sentimenata rečenica. Da bi procijenili uspješnost automatske analize usporedili su je s rezultatima dobivenim tijekom ručne analize, za koju su metodom slučajnog odabira odabrali šesto rečenica. U ručnoj analizi, koja se smatra zlatnim standardom, 80 % rečenica ocijenjeno je negativno, 12 % pozitivno i 7 % neutralno. Nakon što su odabrali najuspješniji algoritam i proveli automatsku analizu na cjelokupnom uzorku, za svakog su kandidata i za svaki dan izradili tablicu u kojoj je bilo prikazano nekoliko varijabli koje su se računale pomoću: omjera pozitivnih i negativnih rečenica, omjera pozitivnih rečenica i ukupnog broja pozitivnih i negativnih rečenica; omjera negativnih rečenica i ukupnog broja pozitivnih i negativnih rečenica, omjera pozitivnih rečenica i ukupnog broja pozitivnih rečenica o svim kandidatima te omjera negativnih rečenica i ukupnog broja negativnih rečenica o svim kandidatima. Navedene su varijable usporedili s rezultatima predizbornih anketa koje su se provodile u navedenom razdoblju i pomoću Pearsonovog koeficijenta korelacije uočili da je za dva kandidata postojala velika povezanost između udjela pozitivnih i negativnih rečenica i rezultata predizbornih anketa, a za jednog umjerena. Drugim riječima, kada bi se udio pozitivnih rečenica o kandidatu u nekom razdoblju povećavao, povećavao bi se i broj birača koji su mu bili skloni. Naposljetku, zaključili su da većina komentara izražava negativne sentimente i frustracije vezane uz politiku (Tumitan & Becker, 2013, p. 6).

Carvalho et al. (2011) ručno su na portugalskom novinskom portalu Público analizirali komentare građana koji su se odnosili na kandidate najvećih portugalskih stranaka, a napisani su na deset novinskih članaka o TV debatama koje su bile upriličene uoči izbora za portugalski parlament 2009. Prikupljeno je 2795 komentara i otprilike 8000 rečenica, a svaka je rečenica predstavljala jedinicu analize i mogla je u odnosu na izraženi sentiment poprimiti brojčane vrijednosti: -2, -1, 0, 1 i 2, gdje je vrijednost -2 pridruživana rečenici sa snažnije izraženim negativnim sentimentom, -1 rečenici sa slabije izraženim negativnim sentimentom, 0 rečenici s neutralnim sentimentom, 2 rečenici sa snažnije izraženim pozitivnom sentimentom, 1 sa slabije izraženim pozitivnim sentimentom te 0 rečenici s neutralnim sentimentom. Utvrđeno je da je u 60 % rečenica bilo izraženo negativno mnijenje, u 15 % pozitivno, u 13 % neutralno, a za 14 % rečenica utvrđeno je da nisu imale izražena mnijenja ili su bile nejasne. Samo je za jednog političara bio uravnotežen broj pozitivnih i negativnih komentara, dok su za sve ostale političare prevladavali negativni komentari. Najviše negativnih komentara napisano je o kandidatu koji je dva puta bio izabran za premijera, a najmanje o kandidatu koji je na izborima 2009. dobio najmanji postotak glasova. Uočena je velika povezanost između broja glasova koji je dobio

pojedini kandidat i broja komentara napisanih o njemu, bilo pozitivnih ili negativnih. Također, uočena je gotovo savršena povezanost između broja ironičnih i negativnih komentara o pojedinom kandidatu. Naposljetku, Carvalho et al. (2011, p. 568) zaključili su da su tijekom predizborne kampanje za parlament 2009. u komentarima na novinskom portalu Público bila znatno izraženija negativna mnijenja nego li pozitivna, što se može obrazložiti sklonošću građana da češće reagiraju kad se s nečim ne slažu, jer na taj način izražavaju svoje frustracije, a mogućnost pisanja komentara pod pseudonimom to im olakšava. Nadalje, uočili su da je 11 % rečenica bilo ironično i da bi se takve rečenice mogle pogrešno procijeniti kao pozitivne, pa su predložili da se tijekom dubinskog istraživanja mnijenja najveća pozornost posveti preciznom utvrđivanju pozitivnih mnijenja.

Balasubramanyan et al. (2012) analizirali su uoči predsjedničkih izbora 2008. komentare građana novinara na pet američkih blogova, od kojih su neki, s obzirom na većinske političke sklonosti svojih korisnika bili ocijenjeni kao liberalni, a drugi kao konzervativni. Automatskom analizom određen je polaritet komentara, tako da su uočene riječi koje izražavaju sentimente i za svaki su blog bile navedene u posebno izrađenim leksikonima tipičnim za zajednicu građana novinara na pojedinome blogu. Ukoliko je u komentaru bilo više riječi s pozitivnim polaritetom, on je ocijenjen kao pozitivan, a ukoliko je bilo više riječi s negativnim polaritetom, on je ocijenjen kao negativan. Naposljetku su uočili da je za svaki blog drugačiji odnos pozitivnih i negativnih komentara. Na jednom liberalnom i jednom konzervativnom blogu dominirali su pozitivni komentari, a na jednom konzervativnom i dva liberalna bloga dominirali su negativni komentari. Također, uočili su da je jakost izraženih sentimenata povezana s temom te da su jakost dominantno izraženih sentimenata i ukupan broj komentara o nekoj temi povezani. Zbog toga su zaključili da teme koje izazivaju jake pozitivne ili negativne sentimente izazivaju i veći broj komentara.

Abdulla et al. (2014, p. 110) ručno su analizirali 6921 osvrta i komentara napisanih na društvenom mediju Yahoo!-Maktoob, najpopularnijem u arapskom svijetu. Uočili su da se udio pozitivnih i negativnih sentimenata u osvrtima i komentarima mijenja u ovisnosti o temi na koju su se ti osvrti i komentari odnosili. Tako je najviše negativnih sentimenata bilo izraženo u osvrtima i komentarima koji su se odnosili na politiku (65, 5%), a najmanje u onima koji su se odnosili na umjetnost (31, 43%). Najmanje pozitivnih sentimenata bilo je izraženo u osvrtima i komentarima koji su se odnosili na politiku (10, 36 %), a najviše u onima koji su se odnosili na umjetnost (34, 4%). Osvrti i komentari koji se odnosili na politiku imali su najmanje neutralnih komentara (19, 35%). Možemo zaključiti da je i istraživanje ovih autora pokazalo

kako građani novinari o političkim temama izražavaju snažne i dominantno negativne sentimente.

Jensen (2014, p. 56) je tijekom svog longitudinalnog istraživanja na tri analizirana danska foruma Dk.politik, Cafe Euroinvestor i Trendsales uočila da je prosječni ton komentara bio pozitivan. Pozitivan ton imali su komentari koji su izražavali poštovanje prema drugim sudionicima, koji su bili racionalni i vezani uz temu konverzacije, a negativni ton imali su komentari u kojima su bile izražene uvrede prema drugim sudionicima ili prema neki trećim osobama.

2. Metodologija

Za utvrđivanje odlika konverzacije građana novinara na internetu i analizu u njima izraženih sentimenata odabrano je kvantitativno istraživanje i primijenjen je pozitivistički pristup čije su odlike: provjera teorija i hipoteza, uočavanje uzročnih veza, proučavanje povezanosti među varijablama ili razlika među skupinama (Kazdin, 1998, navedeno u Milas, 2005) te brojčano određivanje istraživanih pojava (Milas, 2005). Varijable koje Vujević (2006: 92) definira kao „promjenljiva obilježja o kojima u hipotezama nešto tvrdimo“ u ovom su istraživanju bili: SO komentara građana novinara o kandidatima te strukturalni i sadržajni pokazatelji konverzacije: razina interaktivnosti, razina polemičnosti i razina argumentiranosti. Sve su varijable bile kvantitativne, jer su se brojčano izražavale i mijenjale (Hoskin, 2012). Određivanje SO komentara provedeno je na temelju fizičkih informacija u tekstu – uporabljenih riječi i izraza koji su izražavali sentimente.

Kao metode prikupljanja podataka odabrane su studija više slučajeva (eng. cross – case analysis) kao poseban oblik studije slučaja (eng. case study) i sadržajna analiza komentara građana novinara. U analizu su uključena tri nacionalna portala: 24 sata, Indeks i T-portal te dva regionalna portala: Slobodna Dalmacija i Dalmacija News. Izvršena je ručna analiza sentimenata izraženih u 15 715 komentara koji su se odnosili na devet kandidata za izbor splitskog gradonačelnika i odlike 604 konverzacija građana novinara objavljenih uz novinske članke koji su se odnosili na kandidate za izbor splitskog gradonačelnika. Tijekom analize izrađen je rječnik s 4913 riječi i izraza koji izražavaju sentimente.

2.1. Studija više slučajeva

Odabrano je nekoliko primjera istraživane pojave – konverzacije građana novinara na različitim novinskim portalima u vrijeme lokalnih izbora za splitskoga gradonačelnika 2013., zbog čega ovo istraživanje metodološki predstavlja studiju više slučajeva, kao podvrstu metode studija slučaja. Naime, studiju slučaja Thomas (2011) opisuje kao istraživačku strategiju koja se odnosi na „analizu osoba, događaja, odluka, razdoblja, projekata, politika, institucija ili drugih sustava koji se cjelovito proučavaju s jednom ili više metoda“ te uočava da je u sklopu studije slučaja, radi usporedbe rezultata, moguće odabrati nekoliko slučajeva. Takvo

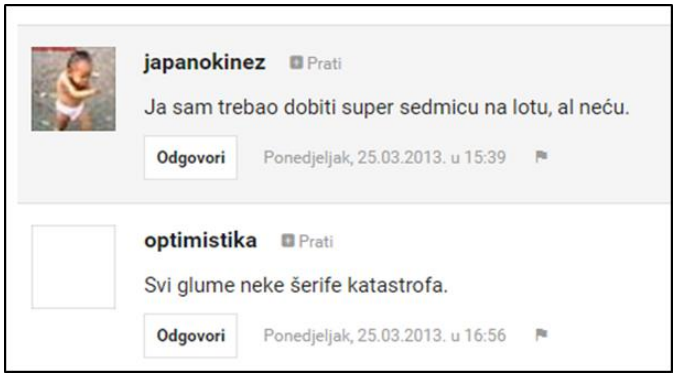
istraživanje Schwandt (2001, navedeno u Thomas, 2011) naziva studija više slučajeva (engl. cross-case analysis).

Tablica 1. Broj posjeta stranicama u razdoblju od siječnja do svibnja 2013. na odabranim mrežnim portalima (Gemius Audience).

	Indeks	*24 sata*	*T - portal*	*Slobodna Dalmacija*	*Dalmacija News*
siječanj-13	22257938	21535356	13093536	4032809	1522379
veljača-13	20487850	19762407	12027453	3796245	1466682
ožujak-13	22140165	21572290	12696741	4007665	1467678
travanj-13	20846731	20143292	12026173	3755939	1479909
svibanj-13	20875111	21231599	12384404	4157275	1709142
Ukupno	106607795	104244944	62228307	19749933	7645790

Tablica 1. prikazuje broj posjeta stranicama odabranih portala u razdoblju od siječnja do svibnja 2013. (Gemius Audience). Pri odabiru slučajeva odabrana je strategija različitosti među slučajevima (eng. diverse case method), a različitost se uočila na temelju podjele novinskih portala u nekoliko kategorija. Nakon toga se iz svake kategorije odabrao po jedan novinski portal (Seawright & Gerring, 2008). Napravljeno je pet kategorija novinskih portala na temelju: lokacije uredništva novinskih portala, djelatnosti nakladnika, postojanja tiskanog izdanja dnevnih novina. Do podataka o pojedinom portalu došlo se pomoću: mrežnih baza podataka (Poslovna Hrvatska; Financijski podaci i poslovne informacije), informacija objavljenih na stranicama portala te telefonskog kontaktiranja redakcija portala. S obzirom na lokaciju uredništva uzeti su u obzir portali kojima je lokacija uredništva u Splitu ili Zagrebu. Novinski portali kojima je lokacija uredništva u Splitu označeni su kao regionalni, a oni kojima je lokacija uredništva bila u Zagrebu kao nacionalni. S obzirom na djelatnost nakladnika portali su podijeljeni u dvije skupine: oni kojima je primarna djelatnost izdavaštvo i oglašavanje u medijima te oni kojima je primarna djelatnost nešto drugo. S obzirom na postojanje tiskanog izdanja dnevnih novina portali su podijeljeni također u dvije skupine: oni koji imaju tiskano izdanje dnevnih novina i oni koji nemaju tiskano izdanje dnevnih novina. Na taj su se način portali svrstali u pet kategorija: nacionalni portali s tiskanim izdanjem dnevnih novina, nacionalni portali bez tiskanog izdanja dnevnih novina, portali čijem nakladniku primarna djelatnost nije izdavaštvo i oglašavanje u medijima, regionalni portali s tiskanim izdanjem dnevnih novina, regionalni portali bez tiskanog izdanja dnevnih novina. U svakoj je kategoriji odabran po jedan portal, i to onaj koji je imao najveći broj posjeta stranicama u razdoblju od siječnja do svibnja 2013., kada su građani novinari pisali komentare obuhvaćene ovim

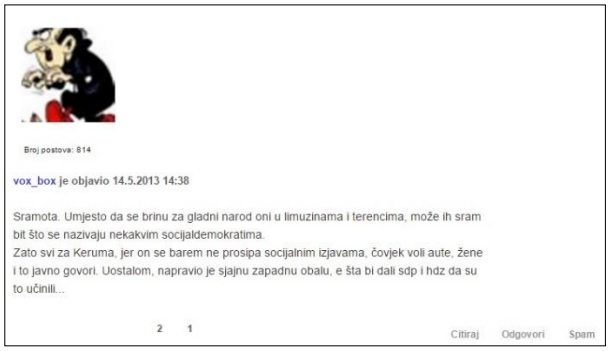
istraživanjem. Podaci o posjećenosti preuzeti su od mrežne istraživačke agencije Gemius Audience. Kriterij najvećeg broja posjeta stranicama odabran je s namjerom da se osigura dovoljno velik broj komentara potrebnih za istraživanje. Od parametra koje Gemius Audience koristi kao pokazatelje posjećenosti stranice odabran je broj posjeta stranicama (eng. visits), a ne broj stvarnih korisnika stranica (eng. real usesrs), budući da su iz broja stvarnih korisnika stranica isključeni korisnici mobilnih aplikacija. Posjete su definirane kao „ukupan broj posjeta na zadanom čvoru kojeg su generirali Internet korisnici u zadanom vremenskom periodu“, a jedna posjeta je definirana kao „ neprekinuta serija prikaza stranica na internetskoj stranici izvršena od strane istog posjetitelja, a brojena kao zatvorena cjelina“ (Gemius Audience). Naposljetku su odabrani novinski portali : 24 sata (nacionalni portal s tiskanim izdanjem dnevnih novina), Indeks (nacionalni portal bez tiskanog izdanja dnevnih novina), T-portal (portal čijem nakladniku primarna djelatnost nije izdavaštvo i oglašavanje u medijima), Slobodna Dalmacija (regionalni portal s tiskanim izdanjem dnevnih novina) i Dalmacija News (regionalni portal bez tiskanog izdanja dnevnih novina). Osim što su odabrani iz različitih kategorija, navedeni su se portali međusobno razlikovali i prema: ukupnom broju posjeta stranicama u istraživanom razdoblju, vrsti temeljnog kapitala njihovog nakladnika (strani, domaći ili kombinirano), godini pokretanja i pravnom statusu nakladnika (dioničko društvo ili društvo s ograničenom odgovornošću), izgledu sučelja i mogućnosti interakcije građana novinara tijekom pisanja komentara.



Slika 5. Izgled sučelja s komentarima na portalu 24 sata

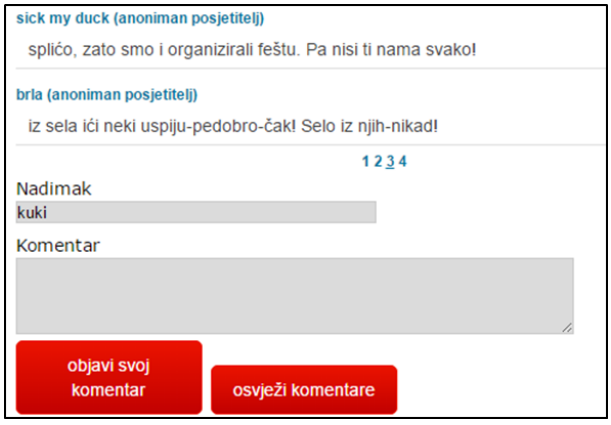
Slika 5. prikazuje izgled sučelja s komentarima na portalu 24 sata. Na ovom portalu građani novinari imali su mogućnost odgovaranja na nečiji komentar pritiskom na gumb „odgovori“. Uz svaki komentar bilo je istaknuto ime autora komentara, datum i vrijeme pisanja komentara te profilna slika autora komentara. Na portalu su komentare mogli pisati samo registrirani korisnici. Nakladnik portala 24 sata bilo je društvo s ograničenom odgovornošću

24sata d.o.o., čija je primarna djelatnost bila izdavanje novina. Temeljni kapital bio je strani. U istraživanom razdoblju imao je oko 100 milijuna posjeta. Portal je pokrenut 2005. godine. Uz portal, ovaj je nakladnik izdavao i tiskane dnevne novine 24sata (Poslovna Hrvatska; Financijski podaci i poslovne informacije).



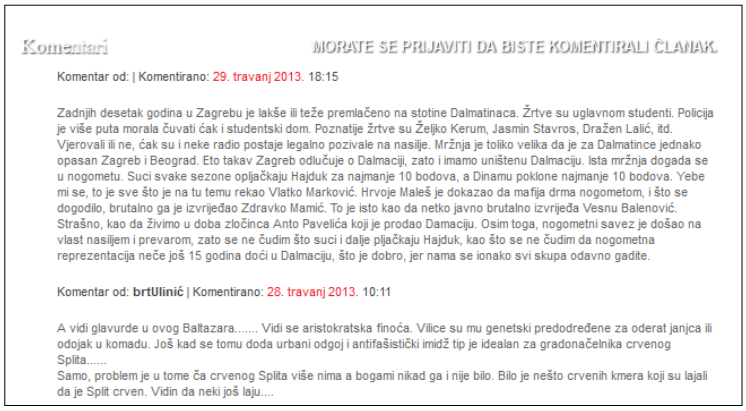
Slika 6. Izgled sučelja s komentarima na portalu Index

Slika 6. prikazuje izgled sučelja s komentarima na portalu Indeks. Na ovom portalu građani novinari imali su mogućnost odgovaranja na nečiji komentar pritiskom na gumb „odgovori“, mogućnost citiranja nečijeg komentara pritiskom na gumb „citiraj“ i mogućnost prijave neželjenog komentara pritiskom na gumb „spam“. Uz svaki komentar bilo je istaknuto ime autora komentara te datum i vrijeme pisanja komentara. Na portalu su komentare mogli pisati samo registrirani korisnici. Nakladnik portala Indeks bilo je društvo s ograničenom odgovornošću Indeks promocija d.o.o., čija je primarna djelatnost bila oglašavanje preko medija. Temeljni kapital bio je domaći. U istraživanom razdoblju imao je oko 100 milijuna posjeta. Portal je pokrenut 2002. godine. Nakladnik nije imao tiskanog izdanja dnevnih novina (Poslovna Hrvatska; Financijski podaci i poslovne informacije).



Slika 7. Izgled sučelja s komentarima na T-portalu

Slika 7. prikazuje izgled sučelja s komentarima na T-portalu. Na ovom portalu građani novinari nisu imali mogućnost odgovaranja na nečiji komentar pritiskom na gumb „odgovori“, a da je komentar odgovor na prethodni moglo se ustvrditi iz samog konteksta ili ako je u komentaru spomenuto ime autora komentara. Uz svaki komentar bilo je istaknuto ime autora komentara. Za pisanje komentara na portalu nije bila potrebna prethodna registracija korisnika. Nakladnik T-portala bilo je dioničko društvo Hrvatski Telekom HT d.d., čija su primarna djelatnost bile žičane telekomunikacije. Temeljni kapital bio je 51% strani, a 49 % domaći. U istraživanom razdoblju imao je oko 60 milijuna posjeta. Portal je pokrenut 2001. godine kada je nosio naziv HTnet, a 2004. promijenio je naziv u T-portal. Nakladnik nije imao tiskanog izdanja dnevnih novina (Poslovna Hrvatska; Financijski podaci i poslovne informacije).


Komentari

MORATE SE PRIJAVITI DA BISTE KOMENTIRALI ČLANAK.

Komentar od: | Komentirano: 29. travanj 2013. 18:15

Zadnjih desetak godina u Zagrebu je lakše ili teže premlačeno na stotine Dalmatinaca. Žrtve su uglavnom studenti. Policija je više puta morala čuvati ćak i studentski dom. Poznatije žrtve su Željko Kerum, Jasmin Stavros, Dražen Lalić, itd. Vjerovali ili ne, ćak su i neke radio postaje legalno pozivale na nasilje. Mržnja je toliko velika da je za Dalmatince jednako opasan Zagreb i Beograd. Eto takav Zagreb odlučuje o Dalmaciji, zato i imamo uništenu Dalmaciju. Ista mržnja dogada se u nogometu. Suci svake sezone opljačkaju Hajduk za najmanje 10 bodova, a Dinamu poklone najmanje 10 bodova. Yebe mi se, to je sve što je na tu temu rekao Vlatko Marković. Hrvoje Maleš je dokazao da mafija drma nogometom, i što se dogodilo, brutalno ga je izvrijeđao Zdravko Mamić. To je isto kao da netko javno brutalno izvrijeđa Vesnu Balenović. Strašno, kao da živimo u doba zločinca Anto Pavelića koji je prodao Damaciju. Osim toga, nogometni savez je došao na vlast nasiljem i prevarom, zato se ne čudim što suci i dalje pljačkaju Hajduk, kao što se ne čudim da nogometna reprezentacija neče još 15 godina doći u Dalmaciju, što je dobro, jer nama se ionako svi skupa odavno gadite.

Komentar od: **brtUlinić** | Komentirano: 28. travanj 2013. 10:11

A vidi glavurde u ovog Baltazara..... Vidi se aristokratska finoća. Vilice su mu genetski predodređene za oderat janjca ili odojak u komadu. Još kad se tomu doda urbani odgoj i antifašistički imidž tip je idealan za gradonačelnika crvenog Splita.....
Samo, problem je u tome ča crvenog Splita više nima a bogami nikad ga i nije bilo. Bilo je nešto crvenih kmera koji su lajali da je Split crven. Vidin da neki još laju....

Slika 8. Sučelje s komentarima na portalu Slobodna Dalmacija

Slika 8. prikazuje izgled sučelja s komentarima na portalu Slobodna Dalmacija. Na ovom portalu građani novinari nisu imali mogućnost odgovaranja na nečiji komentar pritiskom na gumb „odgovori“, a da je komentar odgovor na prethodni moglo se ustvrditi iz samog konteksta ili ako je u komentaru spomenuto ime autora komentara. Uz svaki komentar bilo je istaknuto ime autora komentara te datum i vrijeme pisanja komentara. Za pisanje komentara na portalu bila je potrebna prethodna registracija korisnika. Nakladnik portala Slobodna Dalmacija bilo je dioničko društvo Slobodna Dalmacija d.d., čija je primarna djelatnost bila izdavanje novina. Temeljni kapital bio je domaći. U istraživanom razdoblju imao je oko 20 milijuna posjeta. Portal je pokrenut 2008. godine. Nakladnik je imao tiskano izdanje dnevne novine (Poslovna Hrvatska; Financijski podaci i poslovne informacije).



Slika 9. Sučelje s komentarima na portalu Dalmacija News

Slika 9. prikazuje izgled sučelja s komentarima na portalu Dalmacija News. Na ovom portalu građani novinari imali su mogućnost odgovaranja na nečiji komentar pritiskom na gumb „reply“. Uz svaki komentar bilo je istaknuto ime autora komentara, datum i vrijeme pisanja komentara te profilna slika autora komentara. Za pisanje komentara na portalu bila je potrebna prethodna registracija korisnika. Nakladnik portala Dalmacija News bilo je društvo s ograničenom odgovornošću Sto Posto d.o.o., čija je primarna djelatnost bila internetski portali. Temeljni kapital bio je domaći. U istraživanom razdoblju imao je oko 7 milijuna posjeta. Portal je pokrenut 2008. Nakladnik nije imao tiskano izdanje dnevne novine (Poslovna Hrvatska; Financijski podaci i poslovne informacije).

2.2. Odabir i pohrana uzorka

U istraživanju se nije pristupilo probabilističkom uzorkovanju komentara napisanih uz određeni članak, jer ne postoji dokaz da su stavovi i uvjerenja normalno distribuirani u populaciji (Marshall, 1996). Također, uzeti su u obzir svi objavljeni članci u navedenom razdoblju, budući da političari, novinari i ostali sudionici javne sfere stalno utječu jedni na druge (Nickels, 2005), pa tako i sama tema članka, kao i način na koji je obrađena, utječu na stavove izražene u komentarima građana novinara. Zbog toga su na svim istraživanim portalima u istraživanje uključeni svi komentari i konverzacije građana novinara na pet odabranih novinskih portala u vremenskom razdoblju od 01. siječnja do 17. ožujka 2013. te od početka kampanje 18. ožujka do njenog kraja 17. svibnja. Odabrano je duže razdoblje od trajanja same službene kampanje budući da su neki kandidati za splitskog gradonačelnika svoje kandidature službeno objavili i prije početka kampanje, čime je kampanja za izbor splitskog gradonačelnika praktički započela i prije službenoga roka. Komentari građana novinara preuzeti su s mrežnih stranica novinskih portala na kojima su arhivirani. Web stranice s komentarima korisnika novinskih portala spremljene su u izvornome web obliku. Pohrana komentara izvršena je u lipnju 2013. U

odabranom uzorku bilo je 3937 građana novinara, 15 715 komentara i 604 konverzacije objavljene uz članke.

Kandidati za splitskog gradonačelnika na lokalnim izborima 2013. bili su: Ivo Baldasar, Sanja Bilač, Vjekoslav Ivanišević, Željko Kerum, Anđelka Visković, Marijo Popović, Marijana Puljak, Hrvoje Tomasović, Damir Vidošević, Anđelka Visković, Pero Vučica i Tomislav Zaninović (Zbirna lista pravovaljanih kandidatura za izbor gradonačelnika grada Splita, 2013).

Svaki je kandidat dobio pripadajuću oznaku:

a) BAL (Ivo Baldasar)
b) BIL (Sanja Bilač)
c) IVA (Vjekoslav Ivanišević)
d) KER (Željko Kerum)
e) VIS (Anđelka Visković)
f) POP (Marijo Popović)
g) PULJ (Marijana Puljak)
h) TOM (Hrvoje Tomasović)
i) VID (Damir Vidošević)
j) VIS (Anđelka Visković)
k) VUČ (Pero Vučica)
l) ZAN (Tomislav Zaninović)

Svaki je novinski članak na istraživanome portalu dobio oznaku iz koje se iščitava na kojeg se kandidata članak odnosio i kojeg je datuma objavljen. Primjerice, oznaku „Ker 0304“ dobio je članak o kandidatu Željku Kerumu objavljen 03. travnja. Ako je istoga dana na tom portalu bilo objavljeno više članaka o kandidatu, oznaci su se dodavala mala slova abecede. Tako se članak označen kao „Ker 0304a“ odnosio na drugi članak o Željku Kerumu objavljen na tom portalu. Ako se članak odnosio na više kandidata, označavao se kao zajednički, pa je je u njegovoj oznaci uporabljen izraz „Zaj“. Primjerice, oznaku „Zaj 0205“ dobio je članak o više kandidata objavljen 02. svibnja. Odluka o tome odnosi li se članak na jednog ili više kandidata donosila se na temelju naslova članka. Ukoliko se u naslovu članka spominjao kandidat ili njegovi bliži suradnici, tada se smatralo da se članak odnosi na tog kandidata.

Na portalu Slobodna Dalmacija za neke članke nije bilo mogućnosti pisanja komentara. Oni su također pohranjeni i uzeti u obzir u određivanju ukupnog broja članaka napisanih o nekom kandidatu, ali nisu uzeti u obzir pri izračunu centralnih vrijednosti razine rasprave na tom mrežnom portalu, budući da za takve članke nije bilo mogućnosti konverzacije.

2.3. Sadržajna analiza

Metodama za prikupljanje podataka dobivamo osjetilne informacije o stvarnosti koja je predmet istraživanja, pri čemu podatke definiramo kao simbolički registrirane činjenice, a činjenice kao osjetilne doživljaje stvarnosti (Vujević, 2006, p. 118). U ovom je istraživanju kao metoda prikupljanja podataka odabrana sadržajna analiza teksta koju je Berelson (1952: 18, navedeno u Murphy& Ciszewska-Carr, 2005, p. 1) definirao kao „istraživačku tehniku za objektivni, sustavni i kvantitativni opis manifestiranog sadržaja komunikacije“. Kolbe i Burnett (1991: 243, navedeno u Murphy& Ciszewska-Carr, 2005, p. 1) ponudili su širu definiciju te istraživačke metode nazvavši je opservacijskom metodom koja se koristi za „sustavno vrednovanje svih oblika simboličkog sadržaja zabilježene komunikacije“, dok Vujević (2006: 153) analizu sadržaja definira kao „metodu za prikupljanje podataka iz informacijskog materijala: iz knjiga, časopisa, novina, s radija, televizije i interneta“. U istraživanju je analiziran je manifestirani i latentni sadržaj komentara. Manifestirani sadržaj lako se uoči, i to na temelju pojavljivanja određenih riječi u tekstu, dok latentni sadržaj zahtijeva interpretaciju (Potter & Levine-Donnerstein, 1999). Primjerice, građani novinari mogu biti ironični. Istraživač, kada analizira komentar građanina novinara, na temelju uvida u sve njegove komentare, zaključuje radi li se o ironiji koja je definirana kao podrugljiv način izražavanja čiji je smisao oprečan kazanom (Anić, 1991, p. 208). Također, određivanje SO komentara izražene u nekom izrazu traži interpretaciju istraživača.

2.3.1. Kategorizacija odlika kandidata

Analizi sadržaja prethodilo je uobičajeno određivanje kategorija analize sadržaja (Vujević, 2006), što je u ovom istraživanju predstavljalo kategoriziranje aspekata entiteta (kandidata za izbor splitskog gradonačelnika) prema kojima su građani novinari izražavali sentimente. Pristupilo se početnom čitanju komentara tijekom kojeg je uočeno da građani novinari u komentarima najčešće izražavaju sentimente prema nekoliko odlika (aspekata) kandidata: sposobnost, pristojnost, odgovornost, moralnost, izgled, kriminalnost i domoljublje. Neki se sentimenti nisu odnosili ni na jednu od navedenih odlika, već su izražavali pružanje ili uskraćivanje potpore kandidatu.

Tablica 2. Kategorije aspekata kandidata

POTPORA	
Odluke/Programi/Postupci/Izjave	Odobravanje/neodobravanje
Izbori	izražavanje želje za uspjehom/neuspjehom izražavanje optimizma/pesimizma pozitivan/negativan stav prema glasačima kandidata
pozitivni/negativni osjećaji Osobine ličnosti koje ne spadaju u moralnu kategoriju	ljubav/mržnja; divljenje/gađenje; pohvala/pokuda; poštivanje/vrijeđanje; izrugivanje; zabavan/dosadan; dobar/loš (općenito)
ODGOVORNOST	
Odnos prema radu i obvezama	marljivost/lijenost; plaćanje/neplaćanje dugova, obveza, plaća; ozbiljnost/neozbiljnost; realizacija/nerealizacija obveza i obećanja
Odnos prema materijalnim dobrima	štedljivost/rasipništvo; građenje/uništavanje; unaprjeđivanje/upropaštavanje
MORALNOST	
Vladanje sobom Odnos prema drugima Spolni, bračni i obiteljski odnosi Smisao za zajednicu Obilježja karaktera	skromnost/oholost; umjerenost/neumjerenost; susretljivost/nesusretljivost; dobronamjernost/zlonamjernost; nesebičnost/sebičnost; pouzdanost/nepouzdanost iskrenost/neiskrenost; čovječnost/nečovječnost čednost/bestidnost; spolna suzdržljivost/spolna raspuštenost; poštenje u ljubavi/nepoštenje u ljubavi; čestitost/nečestitost u braku; ljubav i poštovanje obitelji/nedostatak ljubavi i poštovanja demokratičnost/nedemokratičnost; pošten/pokvaren principijelan/neprincipijelan; pravedan/nepravedan hrabar/bojažljiv; odlučan/neodlučan; uporan/popustljiv; dosljedan/nedosljedan; slobodoljubiv/ne poštuje slobodu drugih; karakternost/beskarakternost; moralna osjetljivost/neosjetljivost
SPOSOBNOST	
Stručnost	visoki/niski stupanj naobrazbe; raspolaganje/neraspolaganje posebnim vještinama; zna /ne zna
Inteligencija	pametan/glup; genijalac/debil; može/ne može
PRISTOJNOST	
Ponašanje u javnosti	posjedovanje/neposjedovanje manira; poznavanje/nepoznavanje bontona; civilizirano/primitivno ponašanje i govor
IZGLED	
Tijelo/Odjeća/Frizura	privlačnost/neprivlačnost; pohvala/pokuda; divljenje/ismijavanje
KRIMINALNOST	
Krađa/Profiterstvo/Mito i korupcija	Obrana od optužbi/Optuživanje
DOMOLJUBLJE	
Grad Domovina	Voli/ne voli Obrana/dezerterstvo

U tablici 2. na temelju početnog čitanja komentara navedene su kategorije odlika kandidata prema kojima su građani novinari izražavali sentimente. Potpora kandidatu izražavana je izrazima poput: „bravo!“, „samo naprijed“, „tako treba“, „nadam se da će

pobijediti“ i sl., dok je negodovanje izražavano kroz uvrede i obeshrabrivanja izrazima poput: „neka ode!“, „bojim se da će pobijediti“, „jao nama!“ i sl. Sadržaj takvih komentara brojčano je vrednovan u kategoriji Potpora.

Prema rječniku hrvatskih riječi (Anić, 1991: 674) sposoban je onaj „koji je dorastao zahtjevima rada i života, koji je u stanju nešto postići ili izvesti“. Građani novinari na taj su način komentirali inteligenciju kandidata, njihove govorne vještine i stupanj njihova obrazovanja kao pretpostavku za kvalitetno obnašanje političkih dužnosti. Sposobni su kandidati opisani kao oni koji nešto mogu, pa su primjerice riječi i izrazi:, „može“, „pametan“, „završio fakultet“, „elokventan“ i „zna“, često upotrebljavani za opis sposobnog kandidata, dok su riječi i izrazi: „ne zna“, „ne može“, „glup“, „jedva završio školu“, „slovka“ i sl., upotrebljavani za opis nesposobnog kandidata. Sadržaj takvih komentara brojčano je vrednovan u kategoriji Sposobnost.

Izgled je definiran kao „ono što se izvana vidi“ (Anić, 1991: 225). Građani novinari u komentarima su opisivali frizuru, stil odijevanja i općenito tjelesnu privlačnost kandidata. Kandidati dobrog izgleda opisani su riječima i izrazima poput: „zgodan“, „ima stila“ i sl., dok su kandidati lošeg izgleda opisivani riječima i izrazima poput: „debeo“, „kako netko može biti s njim“ i sl. Sadržaj takvih komentara brojčano je vrednovan u kategoriji Izgled.

Građani novinari komentirali su i moral kandidata, u skladu s definicijom morala kao „ukupnost načela o sudovima, ponašanju i u odnosima među ljudima koja se nameću savjesti pojedinca ili zajednice, a u skladu su s općim pravilima o dobru“ (Anić, 1991: 348). Do kategorija koje se odnose na moralne osobine došlo se pomoću Vukasovićeve kategorizacije moralnih osobina. Naime, Vukasović (1992) je moralne osobine svrstao u devet skupina, u ovisnosti o tome odnose li se na: vladanje sobom; odnos prema drugome čovjeku; spolne, bračne i obiteljske odnose; smisao za zajednicu; odnos prema domovini; odnos prema drugim narodima; odnos prema radu; stavove prema materijalnim i kulturnim dobrima te na obilježja osobe i karaktera.

Uočeno je da su građani novinari pozitivno komentirali odnos kandidata prema radu i materijalnim dobrima riječima i izrazima poput: „napravio“, „izgradio“, zaposlio“ i sl., dok su negativno taj odnos opisali riječima i izrazima poput: „uništio“; „nije dolazio na posao“, nije napravio“, „duguje“ i sl. Sadržaj takvih komentara brojčano je vrednovan u kategoriji Odgovornost, u skladu s definicijom odgovornosti kao „preuzimanja obaveze i dužnosti u obavljanju posla“ (Anić, 1991: 401).

Građani novinari pozitivno su komentirali ponašanje kandidata u javnosti riječima i izrazima poput: „fin“, „civiliziran“, „ima manire“, dok su negativno ponašanje u javnosti opisivali riječima i izrazima poput: „divljak“, „primitivac“, „radi dernek“ i sl. Sadržaj takvih komentara brojčano je vrednovan u kategoriji Pristojnost, u skladu s definicijom pristojnosti kao „ukupnosti pravila ponašanja i izravnog ophođenja prihvaćenoj u društvenoj sredini“ (Anić, 1991: 553).

Građani novinari pozitivno su komentirali odnos kandidata prema domovini i gradu riječima i izrazima poput: „voli grad“, „domoljub“, „Hrvat“ i sl., a negativno taj su odnos opisivali riječima i izrazima poput: „dezerter“, „izdajnik“, „pobjegao u vrijeme rata“ i sl. Sadržaj takvih komentara brojčano je vrednovan u kategoriji Domoljublje, u skladu s definicijom domoljublja kao ljubavi prema domovini (Anić, 1991, p. 119).

Tijekom početnog čitanja komentara uočeno je da su građani novinari kandidate optuživali za kriminalne radnje poput krađe, davanja mita i korupcije riječima i izrazima poput: „ukrao“, „uništio dokaze“, „namješta poslove“ i sl. Sadržaj takvih komentara brojčano je vrednovan u kategoriji Kriminalnost, u skladu s definicijom kriminala kao „izvođenja protuzakonitih i opasnih radnji kao što su prisvajanje imovine i povreda fizičkog integriteta građanina“ (Anić, 1991: 288).

Građani novinari pozitivno su komentirali osobine karaktera kandidata, njegovo vladanje sobom i odnos prema drugim ljudima izrazima i riječima poput: „pomaže“, „iskren“„pošten“, „skroman“, a negativno izrazima i riječima poput: „laže“, „varalica“, „vlastohlepan“, „pije“, „kocka“ i sl. Sadržaj takvih komentara brojčano je vrednovan u kategoriji Moralnost, u kojoj su vrednovani svi komentari koji se odnose na moralnost, a nisu svrstani u kategorije Odgovornost, Pristojnost, Domoljublje ili Kriminalnost.

Svaka je kategorija analize sadržaja dobila pripadajuću oznaku:

a) PO (potpora)

b) SP (sposobnost)

c) PR (pristojnost)

d) OD (odgovornost)

e) MO (moralnost)

f) IZ (izgled)

g) DO (domoljublje)

h) KR (kriminalnost)

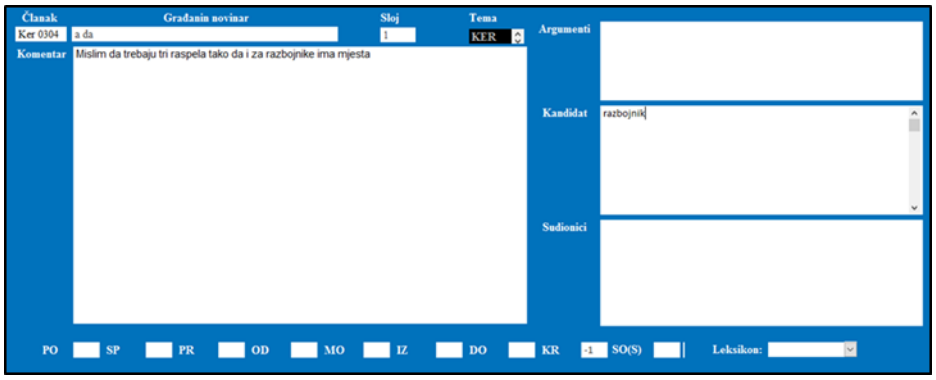
2.3.2. Jedinice analize

Prema Krippendorffu (2004, p. 98) sadržajna analiza pretpostavlja izbor: jedinica uzorka (eng. sampling units), jedinica kodiranja (eng. coding units) i jedinica konteksta (eng. contexts units). Jedinica uzorka sadržajne analize mora sadržavati sve bitne informacije za samu analizu i mora biti neovisna o drugim jedinicama, a ako postoji određena povezanost ona ne smije utjecati na rezultat analize (Krippendorff, 2004, p. 99). Jedinica kodiranja sadržajne analize najmanja je cjelina koja sadrži sve informacije potrebne za analizu (Krippendorff, 2004, p. 100), a jedinica konteksta je cjelina koja omogućava razumijevanje jedinice kodiranja (Krippendorff, 2004, p. 101).

Tijekom analize sentimenata jedinicu uzorka sadržajne analize činili su svi komentari građana novinara napisani uz članak o kandidatu, jedinicu kodiranja predstavljao je komentar, a jedinicu konteksta objavljeni članak sa svim pripadajućim komentarima.

Tijekom analize strukturalnih pokazatelja konverzacije jedinicu uzorka sadržajne analize, jedinicu kodiranja i jedinicu konteksta činili su svi komentari građana novinara napisani uz članak o kandidatu.

2.3.3. Tablice i obrasci za unos podataka



Slika 10. Izgled obrasca u MS Accessu za pohranu podataka tijekom analize sadržaja

Na slici 10. prikazan je obrazac za pohranu podataka tijekom analize sadržaja komentara. Obrazac je sadržavao sljedeća polja:

a) oznaku članka (Članak)
b) naziv građanina novinara (Građanin novinar)
c) pripadajući sloj u konverzaciji (Sloj)
d) sadržaj komentara (Komentar)
e) oznaku kandidata na koji se komentar odnosio (Tema)
f) izraze i riječi koji opisuju kandidata (Kandidat)
g) izraze i riječi koji opisuju građanina novinara - sudionika konverzacije (Sudionici)
h) uporabljeni argumenti (ARG)
i) okvir za pretraživanje riječi i izraza (Leksikon)
j) brojčano vrednovanje SO komentara u kategorijama:
    1. Potpora (PO)
    2. Sposobnost (SP)
    3. Pristojnost (PR)
    4. Odgovornost (OD)
    5. Moralnost (MO)
    6. Izgled (IZ)
    7. Domoljublje (DO)
    8. Kriminalnost (KR)
k) brojčano vrednovanje SO komentara koji se odnose na građane novinare (SO(S))

Za jedan komentar bilo je moguće unijeti više kartica u obrascu ukoliko je u njemu spomenuto više kandidata. Tada se kartica kopirala, a izmijenila bi se samo oznaka kandidata.

GRN	OZČ	SLO	KOM	K	S	ARG	PO	SP	PR	OD	MO	IZ	DO	KR	SO(S)	OZK
a da	Ker 0304	1	Mislim da treb	razbojnik										-1		KER
DEXTER	Ker 0304	1	J3be on narod	Hektor; j							-2					KER
plavi09	Ker 0304	1	Ne znam zašto	slaganje			1									KER
zlatni križ	Ker 0304	1	Po tebi kod na	prestani;			-2				-1		-1	-2		KER
hm	Ker 0304	1	Bože,očuvaj na	zlo; bože			-1				-1					KER
izam izam.	Ker 0304	1	Ma gdje vi vidi	polupism			-1	-1		-1	-2					KER
jovo	Ker 0304	1	moramo stavit	neslagan			-1									KER

Slika 11. Izgled tablice u MS Accessu s podacima unesenim tijekom sadržajne analize

Na slici 11. prikazan je izgled tablice u MS Accessu koja se za svaki novinski portal popunjavala pomoću gore spomenutog obrasca. Tablica je sadržavala stupce:

a) naziv građanina novinara (GRN)
b) oznaka članka (OZČ)
c) Sloj (SLO)
d) komentar (KOM)
e) riječi i izrazi koji se odnose na kandidata (K)
f) riječi i izrazi koji se odnose na sudionike konverzacije – građane novinare (S)
g) riječi i izrazi koji predstavljaju valjane argumente (ARG)
h) brojčano izraženu SO komentara koji su se odnosili na kandidate u pojedinim kategorijama (PO, SP, PR, OD, MO, IZ, DO, KR)
i) brojčano izraženu SO komentara koji su se odnosili na sudionike konverzacije - građane novinare (SO(S))
j) oznaku kandidata na koji se komentar odnosi (OZK)

U ukupnom broju analiziranih komentara bili su i oni koji su se odnosili na neku drugu temu, a nalazili su se u drugom ili višem sloju konverzacije.

Tijekom analize komentara izostavljeni su:

a) komentari ostavljeni nakon objave rezultata (postoje slučajevi da su građani novinari naknadno ostavljali komentare)
b) prvi sloj komentara i svi ostali slojevi koji slijede iz njega, ako se taj komentar nije odnosio na kandidata ili građane novinare

c) komentari kojima se građanina novinara izravno poziva na konverzaciju o temi koja se ne odnosi na kandidata



Slika 12. Obrazac u MS Accessu za unos riječi i izraza koji odražavaju SO komentara

Na slici 12. prikazan je obrazac u MS Accesu za unos riječi i izraza koji odražavaju sentimente. Rječnik s riječima i izrazima koji odražavaju sentimente komentara postupno se izgrađivao tijekom analize komentara. Za svaku se riječ i izraz koji su se odnosili na kandidata određivalo kojoj kategoriji odlike kandidata pripada: PO, SP, PR, OD, MO, IZ, DO, KR. Za svaku riječ i izraz koji su se odnosili na građane novinare pridružena je kategorija SU. Ukoliko su riječ ili izraz odražavali pozitivno svojstvo pridružena je oznaka (+), a ukoliko su odražavali negativno svojstvo pridružena je oznaka (-). Na slici je dan primjer za riječ „diskreditira“ koja je uvrštena u kategoriju MO (moralnost) i predstavlja negativno svojstvo, zbog čega je u polje Oznaka upisano „ MO (-)“. U rječnik su unesene i riječi koje su pojačavale SO imenica i pridjeva, poput „vrlo“, „izuzetno“, „veliko“ i sl, a uvrštene su u kategoriju POJ (pojačivači).

2.3.4. Analiza sentimenata

Tijekom analize komentara koji se odnosio na kandidata uočeni su izrazi i riječi koji odražavaju pozitivnu ili negativnu SO komentara u pojedinim kategorijama sentimenata. Pozitivnim riječima i izrazima pridruživala se brojčana vrijednost 1, a negativnim brojčana vrijednost -1. SO analiziranog komentara u pojedinoj kategoriji računala se prema formuli

$$SO\ (kategorija\ sentimenta) = \sum_i^n SO\ (w_i\ ), \qquad (4)$$

gdje je SO (kategorija sentimenta) ukupna semantička orijentacija teksta s obzirom na izražene sentimente o pojedinoj kategoriji sentimenta; n predstavlja ukupni broj nositelja

sentimenata tekstu koji se odnose na kategoriju sentimenta; a SO (wi) semantička orijentacija riječi ili izraza koji izražava sentiment u toj kategoriji.

Primjer određivanja semantičke orijentacije komentara na T-portalu uz članak o podizanju križa na Marjanu:

> „Ne znam zašto je važno tko ga postavlja a nije važno da ga se postavlja Jedini odgovor je opet napad sotonista i srbočetnika kojima smeta križ i Crkva u Hrvata“

Iz rečenice je razvidno da građanin novinar odobrava postavljanje križa (latentni sadržaj), pa je u kategoriji PO za ovaj komentar SO bila 1. Prema građanima novinarima koji ne odobravaju križ izraženi su negativni sentimenti riječima: „sotonist“ i „srbočetnik“, pa je u kategoriji SU za ovaj komentar SO bila -2.

Tijekom analize komentara koji se odnosio na građane novinare - sudionike konverzacije, uočeni su izrazi i riječi koji odražavaju pozitivnu ili negativnu SO komentara. Riječi i izrazi koji su se odnosili na građane novinare mogli su biti:

a) pozitivni (pohvala, pridijevanje pozitivnih osobina, čestitanje, izražavanje dobrih želja, pozdravljanje)
b) negativni (uvreda, prijetnja, pridijevanje negativnih osobina, negiranje identiteta, izražavanje negativnih želja)

Pozitivnim riječima i izrazima koji su se odnosili na građane novinare pridruživala se brojčana vrijednost 1, a negativnim brojčana vrijednost -1. Ukupna SO komentara dobivala se zbrajanjem svih SO riječi i izraza u komentaru. Neutralnima su se smatrali riječi i izrazi koji su predstavljali: traženje pojašnjenja, ispravljanje gramatike i pravopisa, pozivanje na pozitivno ponašanje, postavljanje pitanja i sl.

Kada su se u komentaru upotrijebile dvije negativne ili dvije pozitivne riječi (izraza) povezane veznikom „ili “vrednovanje se vršilo na sljedeći način:

a) samo se jedna vrednuje ako su obje riječi (izraza) istog predznaka
b) skup riječi (izraza) povezanih veznikom „ili” je neutralan ako riječi (izrazi) nisu istog predznaka

Izrazi kojima se izražava slaganje poput “tako je”, “slažem se” i sl., vrednovali su se kao slaganje s prethodnim komentarom i dobivali su:

a) vrijednost -1 u kategoriji PO, kada je prethodni komentar vrednovan u više kategorija i u svim je bio negativno vrednovan

b) vrijednost -1 u onoj kategoriji u kojoj je prethodni komentar vrednovan, ukoliko je vrednovanje bilo samo u toj kategoriji
c) vrijednost 1 u kategoriji PO, kada je prethodni komentar vrednovan u više kategorija i u svim je kategorijama bio pozitivan
d) vrijednost 1 u onoj kategoriji u kojoj je prethodni komentar vrednovan, ukoliko je vrednovanje bilo samo u toj kategoriji
e) neutralan kada je prethodni komentar imao u nekim kategorijama pozitivne, a drugima negativne vrijednosti

Pozivanje na prihvatljivu komunikaciju u ovom istraživanju vrednovalo se neutralno („nemoj se ljutit “, „budi pristojan “, „ponašaj se demokratski!” i sl.)

Ironija se utvrđivala na temelju analize svih komentara pojedinog građanina novinara i u tom je slučaju SO komentara u pojedinim kategorijama dobivala predznak suprotan od onog koji bi bio da nije riječ o ironiji, a ironični su se izrazi i riječi označavali pomoću navodnika ili umetanjem riječi “nije” ili “nisu” ispred njih.

Ukoliko se uz riječ koja je imala pozitivnu ili negativnu SO nalazila riječ koja je pripadala kategoriji pojačivača, tada bi se jakost SO povećala za jedan, a predznak (pozitivan ili negativan) bi ostao nepromijenjen. Primjerice, za riječ koja odražava sentiment prema sposobnosti kandidata (SP) ,

SO („budala“) = -1 (SP),

SO („velika budala“) = -2 (SP),

Za komparativ pridjeva koji je izražavao sentiment jakost je za SO iznosila 2, a za superlativ jakost je za SO iznosila 3. Primjerice,

SO („glup“) = -1 (SP)

SO („gluplji“) = -2 (SP)

SO („najgluplji“) = -3 (SP)

2.3.5. Analiza argumenata

U ovom istraživanju komentar se smatrao argumentiran ukoliko su u njemu bili navedeni:

a) barem jedna provjerljiva činjenica (npr. “s ljubavnicom ima dijete”, “nikada nije govorio u Saboru” i sl.)
b) barem jedan općeprihvaćeni moralni stav (npr. “čovjek je nevin dok se ne dokaže suprotno”, “dobar znanstvenik ne mora biti dobar političar” i sl.)

Komentar se nije smatrao argumentiranim ukoliko su u njemu bili navedeni:

a) pretpostavke

b) doživljaji

Primjer određivanja argumentiranosti komentara na T-portalu uz članak o podizanju križa na Marjanu:

„roko preko 30% stanovnika Hrvatske nije ni rođeno u toj yugi a ti
se pozivaš na nju da je ona kriva za današnje stanje“

U ovom je argumentu iznesen podatak da preko 30 % današnjih stanovnika Hrvatske nije rođeno u Jugoslaviji, pa se komentar smatrao argumentiranim.

2.3.6. Analiza strukturalnih pokazatelja konverzacije

Građanin novinar	Sloj	K	ARG	PO	SP	PR	OD	MO	IZ	DO	KR	SO (K)
kakogod	1	blesav			-1							-1
nepiswoman	1	egotrip manijak šporka			-1			-2				-3
ivemali	2	neutralno										0
Pere500	1	mutan nelogičan			-1			-1				-2
splitu_s_ljubavlju	1	ih hvala lagalan za sebe hahaha		-2				-2			-1	-5
OLLOA	1	glup šporkao se			-1			-1				-2
Junona	1	hahaha komedija		-2								-2
Ze	1	protiv pokvaren		-1				-1				-2
cemer	1	za sebe						-1				-1
okolokole	1	ilegalno ilegalno nesklapanje		-1							-2	-3

Tema:	h index	nk	n(a)	n(i)	rp	nk (K)	K(+)	K(-)
	1	10	2	1	1,1	10	0	9

Slika 13. Izgled tablice u MS Excellu sa svim komentarima na pojedini članak

Slika 13. prikazuje izgled tablice u MS Excellu sa svim komentarima na pojedini članak pomoću koje su se određivali strukturalni pokazatelji konverzacije. Tablica se dobila iz MS Access tablice tako da su se izdvojili samo oni zapisi koji nose oznaku tog članka. Pri izradi tablice izostavljeni su zapisi u kojima su identični komentari (u slučaju kada je u jednom komentaru komentirano više kandidata). U tablici su navedeni:

a) naziv građanina novinara (Građanin novinar)

b) sloj komentara u konverzaciji (Sloj)

c) riječi i izrazi koji odražavaju SO komentara kandidata (K)

d) riječi i izrazi koji odražavaju argumentiranost komentara (ARG)

e) SO komentara po pojedinim kategorijama (PO, SP, PR, OD, MO, IZ, DO, KR)

f) ukupna SO komentara (SO (K))

Na dnu je tablice naveden h - index komentara na članak, broj komentar n_k, broj argumentiranih komentara n(a) i broj komentara koji ne pripadaju prvom sloju n(i). Najdublji sloj komentara **j** u konverzaciji u kojem ima barem **j** komentara predstavlja h - index, a razina se polemičnosti r_p računala prema formuli

$$r_p = h - index \quad + \frac{1}{n_k}, \tag{1}$$

gdje n_k ukupan broj komentara u konverzaciji.

Ukoliko se članak nije odnosio na više kandidata i nije tematski kategoriziran kao zajednički, u istoj je tablici navedena tema članka, broj komentara koji se odnose na kandidata n_k(K), broj negativnih komentara o kandidatu K (-) i broj pozitivnih komentara o kandidatu K (+), kako bi se radi iscrpnije opisne statistike mogla uočiti naznaka povezanosti određene teme s udjelom pozitivnih i neutralnih komentara o kandidatu. Komentar je o kandidatu bio negativan ukoliko je ukupna SO komentara, koja je predstavljala zbroj SO po pojedinim kategorijama, bila negativna. Komentar je o kandidatu bio pozitivan ukoliko je ukupna SO komentara, koja je predstavljala zbroj SO po pojedinim kategorijama, bila pozitivna.

2.4. Obrada podataka

Za svakog su građanina novinara na nekom novinskom portalu izračunati: ukupna SO komentara o pojedinom kandidatu i ukupna SO komentara o građanima novinarima.

Iz tablice u MS Accessu s podacima o komentarima na nekom novinskom portalu izdvojili su se svi komentari o pojedinome kandidatu napisani u svim konverzacijama na tom portalu, a zatim su se prebacili u MS Excell tablicu iz koje se je nakkkon toga izradila zaokretna tablica.

Građanin novinar	PO	SP	PR	OD	MC	IZ	DO	KR	SO (K)
0:00	-1			-1					-2
Adelaide	-2								-2
advokat.split	-1				-2		-4		-7
Ajme	-1								-1
alpine	-1	-1		-1					-3
amera047	-2	-1			-6				-9
amigo	-1								-1
anarh							-1		-1

Slika 14. Izgled zaokretne tablice u MS Excellu sa SO komentara o kandidatu

Slika 14. prikazuje izgled zaokretne tablice u MS Excellu u kojoj su u prvom stupcu bili navedeni nazivi građana novinara, a u sljedećima su bile upisane:

a) za svakog građanina novinara brojčano izražena ukupna SO svih komentara o kandidatu u odnosu na odlike kandidata (PO, SP, PR, OD, MO, IZ, DO, KR)
b) za svakog građanina novinara brojčano izražena ukupna SO svih komentara o kandidatu, koja je zbroj ukupnih SO komentara u svim kategorijama (SO (K))

Ukoliko pojedini građanin novinar nije komentirao kandidata u određenoj kategoriji, tada se njegov odnos prema kandidatu u toj kategoriji smatrao neutralnim i ukupna SO komentara u toj kategoriji dobivala je vrijednost 0. Određen je i broj građana novinara koji su se o pojedinom kandidatu izjašnjavali pozitivno, negativno i neutralno. Građani novinari o kandidatu su se izjašnjavali pozitivno ukoliko je ukupna SO njihovih komentara o kandidatu bila veća od nule. Građani novinari o kandidatu su se izjašnjavali negativno ukoliko je ukupna SO njihovih komentara o kandidatu bila manja od nule. Građani novinari o kandidatu su se izjašnjavali neutralno ukoliko je ukupna SO njihovih komentara o kandidatu bila 0.

Građanin novinar	SO (S)
vini	1
vino058	-3
volim zute	-22
volimsplit	-3
vranina	-3
vrgorcan	-35
zagorac	-2

Slika 15. Izgled zaokretne tablice u MS Excellu sa SO komentara o građanima novinarima

Slika 15. Prikazuje izgled zaokretne tablice u MS Excellu koja se dobila iz tablice u MS Accessu tako što su se na određenom novinskom portalu izdvojili svi komentari o građanima novinarima napisani u svim konverzacijama na tom portalu. U prvom stupcu zaokretne tablice navedeni su nazivi građana novinara, a u drugome ukupna SO svih komentara pojedinog građana novinara koji su se odnosili na druge građane novinare. Određen je i broj građana novinara koji su se o drugim građanima novinarima izjašnjavali pozitivno, negativno i neutralno. Građani novinari o drugim su se građanima novinarima izjašnjavali pozitivno ukoliko je ukupna SO njihovih komentara o drugim građanima novinarima bila veća od nule. Građani novinari o drugim su se građanima novinarima izjašnjavali negativno ukoliko je ukupna SO njihovih komentara o drugim građanima novinarima bila manja od nule. Građani novinari o drugim su se građanima novinarima izjašnjavali neutralno ukoliko je ukupna SO njihovih komentara o drugim građanima novinarima bila 0.

Dobiveni podaci statistički su se obrađivali tako da su se u MS Excellu za svaki novinski portal računale centralne vrijednosti (srednja vrijednost, medijan i mod) za:

a) SO komentara građana novinara o pojedinom kandidatu, ukupna i po pojedinim kategorijama, gdje je broj mjerenja bio jednak broju građana novinara na novinskom portalu
b) SO komentara građana novinara o drugim građanima novinarima, gdje je broj mjerenja bio jednak broju građana novinara na novinskom portalu
c) razinu interaktivnosti, razinu polemičnosti i razinu argumentiranosti konverzacija na novinskom portalu, gdje je broj mjerenja bio jednak broju članaka na novinskom portalu na koje je bilo moguće pisati komentare

Za svaki se je novinski portal utvrdio broj napisanih članaka o svakom kandidatu, broj komentara o svakome kandidatu i drugim građanima novinarima, broj građana novinara koji su komentirali pojedinog kandidata i druge građane novinare, najviša i najniža vrijednost za ukupne SO komentara pojedinog kandidata, te udio građana novinara koji su se o pojedinom kandidatu i drugim građanima novinarima izjasnili pozitivno, negativno ili neutralno. Na istraživanim portalima članci su se rangirali s obzirom na postotak pozitivnih i negativnih komentara o pojedinom kandidatu te razinu polemičnosti. Za rangiranje članaka s obzirom na postotke pozitivnih i negativnih komentara uzeti su u obzir samo oni članci koji se odnose na pojedinog kandidata, a bili su izuzeti članci posvećeni većem broju kandidata te oni članci koji imaju barem 20 komentara, budući da članci s malim brojem komentara pri ovom rangiranju nisu imali statističku važnost. Kod rangiranja članaka s obzirom na razinu polemičnosti

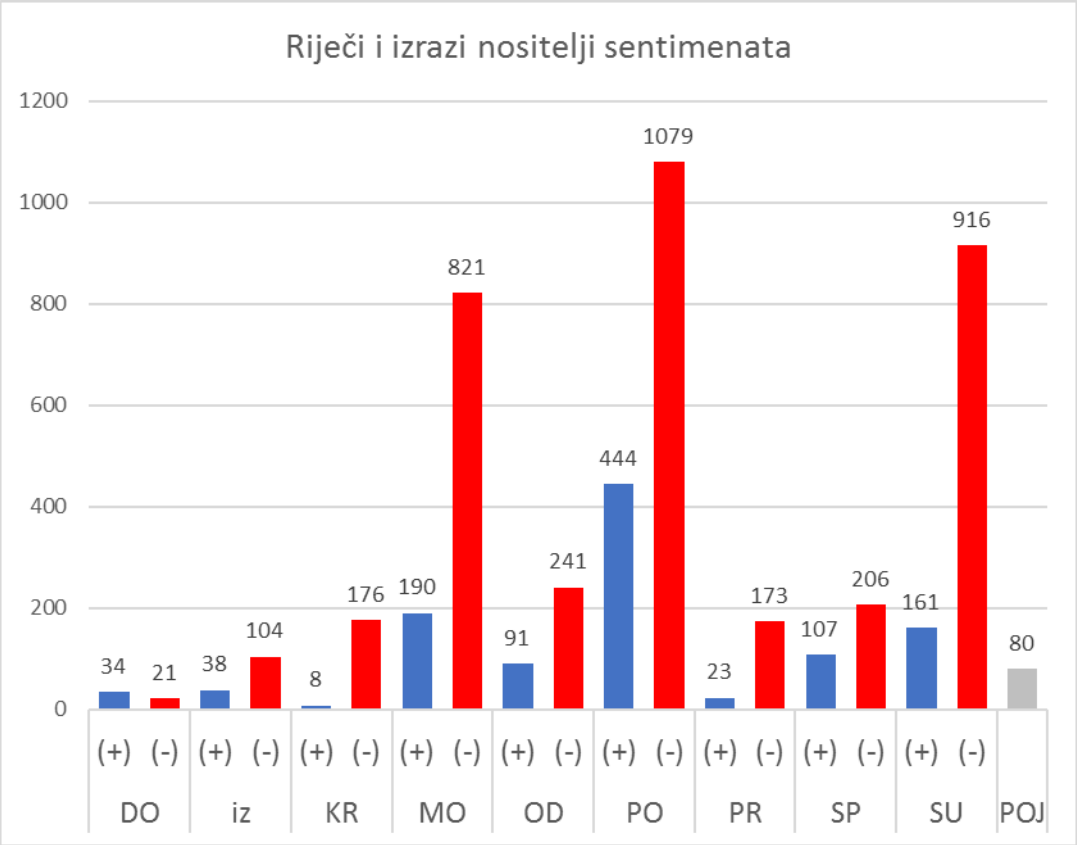
uključeni su svi članci za koje je bilo moguće pisati komentare, budući da je u samoj vrijednosti razine polemičnosti izražena veća ili manja komentiranost članka.

Raspodjele rezultata za ukupne SO komentara, razinu polemičnosti, razinu argumentiranosti i interaktivnosti testirale su se u MS Excellu pomoću Shapiro-Wilkovog testa radi utvrđivanja normalnosti raspodjele rezultata. Pri testiranju sličnosti raspodjele rezultata uzete su u obzir SO komentara koji su se odnosili samo na one kandidate koje je na svakom istraživanom portalu komentiralo barem 20 građana novinara. Utvrđeno je da je barem 20 građana novinara na svim istraživanim portalima komentiralo kandidate: Željka Keruma, Ivu Baldasara i Sanju Bilač, pa se testiranje raspodjele rezultata SO komentara izvršilo samo za ove kandidate.

3. Rezultati istraživanja

3.1. Rječnik za analizu sentimenata

Tijekom analize komentara izdvojeni su riječi i izrazi koji izražavaju sentimente prema entitetima (kandidatima za izbor splitskog gradonačelnika i građanima novinarima) i aspektima entiteta (odlikama kandidata) te pojačivači riječi i izraza koji izražavaju sentimente. Riječima i izrazima pridruživane su negativne ili pozitivne brojčane vrijednosti koje su predstavljale SO u odnosu na entitet ili njegov aspekt te oznake entiteta ili aspekta entiteta. Tako je nastao rječnik od 4913 riječi i izraza, od čega se 3737 (77,32%) odnosilo na riječi izraze sa negativnom SO, a 1096 (22,68%) na riječi i izraze s pozitivnom SO.



Graf 1. Broj riječi i izraza koje izražavaju sentimente

Graf 1. prikazuje broj riječi i izraza koji izražavaju sentimente prema odlikama kandidata, kandidatima i građanima novinarima. U svim se kategorijama uočava dominacija riječi i izraza koji izražavaju negativne sentimente, a najviše ih je bilo u kategorijama MO (821), PO (1079) i SU (916).

3.2. Portal 24 sata

Obrađeno je ukupno 5575 komentara napisanih na 70 novinskih članaka o kandidatima za splitskoga gradonačelnika. Od toga se 4936 komentara odnosilo na kandidate, a 588 na građane novinare.

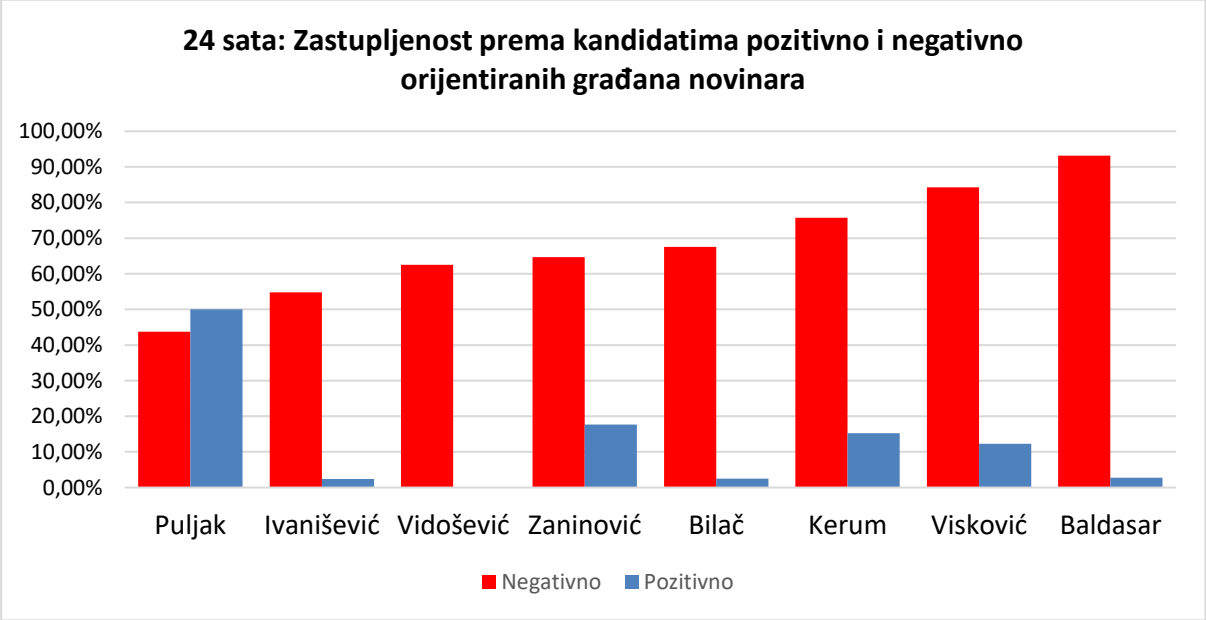
3.2.1. Analiza sentimenata

Tablica 3. SO komentara na novinskom portalu 24 sata

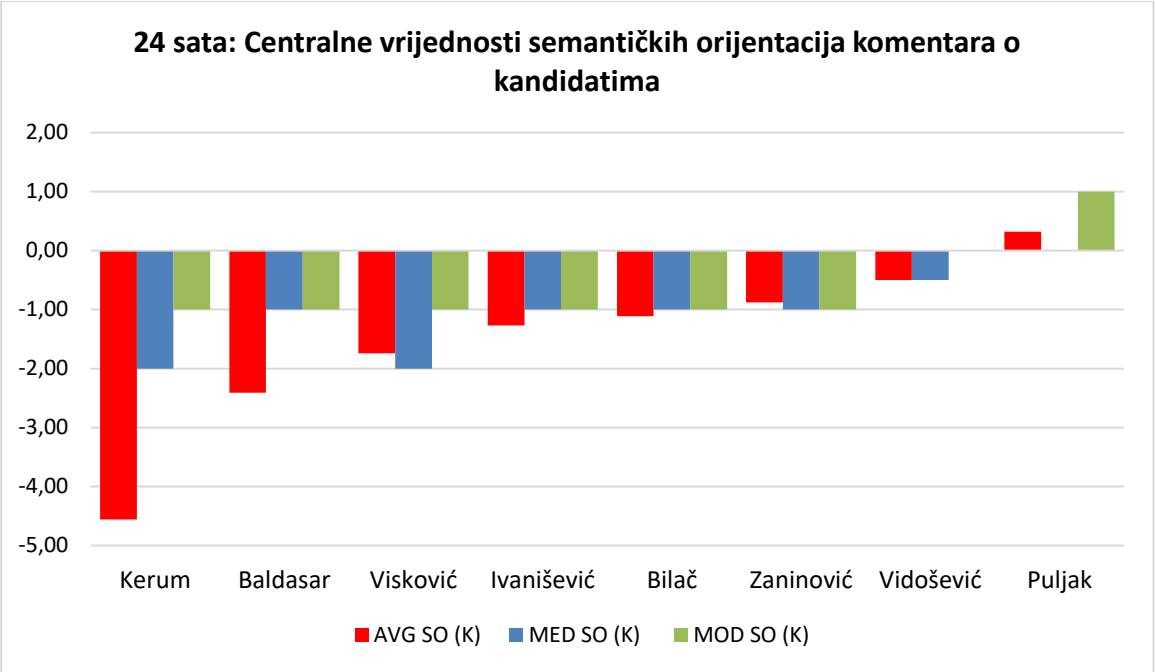
	Br. čl.	Br. kom.	Br. gr. n.	Avg SO	Med SO	Mod SO	Max	Min	Poz	Neg	Neu
Kerum	54	4541	1268	-4,560	-2	-1	69	-149	15,22%	75,71%	9,07%
Baldasar	2	140	78	-2,410	-1	-1	2	-25	2,74%	93,15%	4,11%
Visković	4	92	58	-1,741	-2	-1	2	-9	12,28%	84,21%	3,51%
Ivanišević	1	61	44	-1,273	-1	-1	3	-11	14,29%	76,19%	9,52%
Bilač	4	63	44	-1,114	-1	-1	3	-10	15,00%	77,50%	7,50%
Puljak	1	43	32	0,324	0	1	6	-3	50,00%	43,75%	6,25%
Zaninović	1	22	17	-0,882	-1	-1	2	-5	17,65%	64,71%	17,65%
Vidošević	1	8	8	-0,500	-0,5	0	0	-1	0,00%	62,50%	37,50%
Građani n.		588	297	-0,513	-1	-1	5	-10	37%	60%	3%

Tablica 3. prikazuje rezultate dobivene za centralne vrijednosti SO komentara (SO) o kandidatima i građanima novinarima komentiranima na novinskom portalu 24 sata, broj napisanih članaka o kandidatu, broj komentara o pojedinome kandidatu i građanima novinarima, broj građana novinara koji su komentirali kandidata i druge građane novinare, najvišu i najnižu vrijednost za ukupne SO komentara te udio građana novinara koji su se o kandidatima i građanima novinarima izjasnili pozitivno, negativno ili neutralno. Vidljivo je da je najviše građana novinara s pozitivnim komentarima imala kandidatkinja Marijana Puljak (50%), a najmanje kandidat Damir Vidošević (0%). No, potrebno je uzeti u obzir činjenicu da postoji i veliki nerazmjer u broju komentara o pojedinom kandidatu. Stoga, rezultat dobiven za kandidata Damira Vidoševića nema statističku važnost, budući da ukupan broj komentara o ovom kandidatu iznosi svega 8 i o njemu je komentare napisalo svega 8 građana novinara. S druge pak strane, za kandidata Ivu Baldasara najveći udio građana novinara napisao je negativne komentare (93,15%), pa kad se tome pridoda mali udio građana novinara koji su se pozitivno izjašnjavali o njemu (2,74%), može se zaključiti da je on na dnu ljestvice kojom se

mjeri naklonost građana novinara prema pojedinim kandidatima. Na isti način za Marijanu Puljak moglo bi se ustvrditi da je na vrhu te ljestvice, budući da je uz najveći udio građana novinara koji su se pozitivno izjašnjavali o njoj imala i najmanji udio građana novinara koji su se o njoj negativno izjasnili (43,75%) te su sve tri centralne vrijednosti SO komentara o njoj bile pozitivne ili neutralne. Srednje vrijednosti SO komentara osjetljive su na izrazito negativne ili pozitivne SO komentara pojedinih građana novinara, što se najbolje vidi na primjeru Željka Keruma, za kojeg je srednja vrijednost ukupne SO komentara bila -4,56, dok je medijan iznosio -2. Iz toga se može zaključiti da su pojedini građani novinari imali izrazito negativne komentare o njemu, što je vidljivo i iz najniže ukupne semantičke orijentacije jednog komentara o njemu (-149), čija je jakost gotovo dvostruko veća od ukupne semantičke orijentacije najpozitivnijeg komentara o njemu (69). Pojedini građani novinari imali su izraženije negativne komentare i o Ivi Baldasaru, budući da postoji veća razlika između srednje vrijednosti (-2,41) i medijana (-1) ukupne SO komentara o Ivi Baldasaru. Većina građana novinara o preostalim se kandidatima izjašnjavala negativno, a centralne su vrijednosti ukupne SO komentara o njima bile negativne ili neutralne. Komentari upućeni građanima novinarima također su imali pretežito negativne SO, budući da su sve centralne vrijednosti za ukupne SO komentara o građanima novinarima bile negativne te se veći udio građana novinara izjašnjavao o drugim građanima novinarima negativno (60%).



Graf 2. Zastupljenost prema kandidatima pozitivno i negativno orijentiranih građana novinara na portalu 24 sata



Graf 3. Centralne vrijednosti semantičkih orijentacija komentara o kandidatima na portalu 24 sata

Graf 2. prikazuje udio građana novinara koji su se pozitivno i negativno izjasnili o kandidatima na novinskom portalu 24 sata, a graf 3. prikazuje centralne vrijednosti ukupne SO komentara o pojedinim kandidatima na tom portalu. Iz oba se grafa može zaključiti da su stavovi građana novinara o kandidatima bili pretežito negativni. Pozitivni stavovi prevladavali su samo za kandidatkinju Marijanu Puljak.

Tablica 4. Rezultati Shapiro-Wilkovog testa normalnosti raspodjele rezultata na novinskom portalu 24 sata

	W	p-value	alpha	normal
SO(Ker)	0,53	0,000	0,05	No
SO(Bal)	0,58	0,000	0,05	No
SO(Bil)	0,83	0,000	0,05	No
SO(S)	0,89	0,000	0,05	No
a	0,88	0,000	0,05	No
i	0,98	0,260	0,05	Yes
r_p	0,88	0,000	0,05	No

U tablici 4. prikazani su rezultati testiranja normalnosti raspodjele rezultata pomoću Shapiro – Wilkovog testa za SO komentara kandidata koje je na istraživanim portalima komentiralo barem 20 građana novinara te za razinu polemičnosti, interaktivnosti i

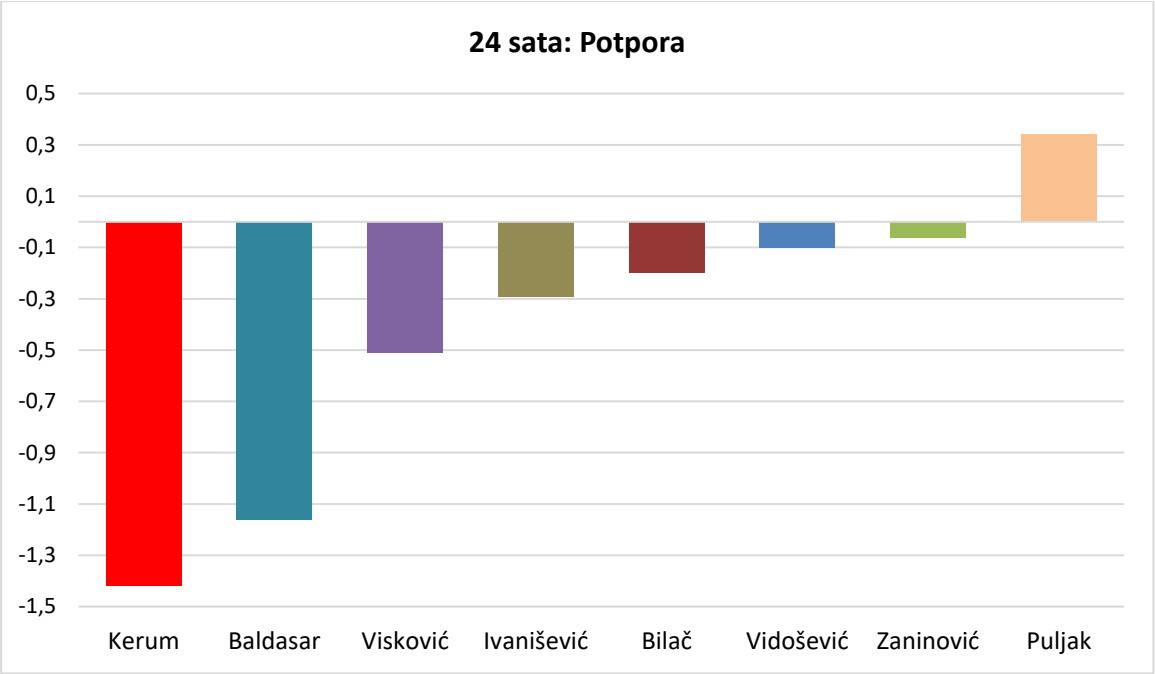
argumentiranosti. Može se zaključiti da raspodjele rezultata za sve varijable, osim za interaktivnost, nisu imale odlike normalne distribucije.

3.2.2. Odlike kandidata

Tablica 5. Srednje vrijednosti SO komentara u odnosu na odlike kandidata

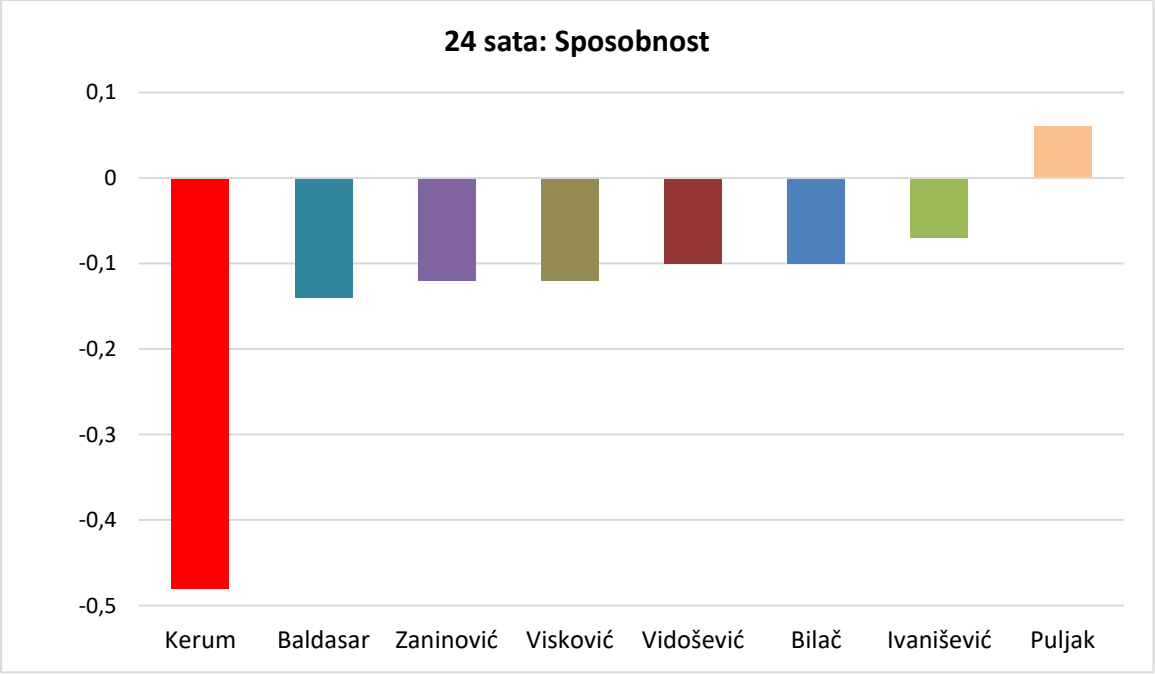
Kandidat	PO	SP	IZ	MO	PR	OD	DO	KR
Baldasar	-1,16	-0,14	0,00	-0,63	-0,01	-0,23	-0,27	-0,12
Kerum	-1,42	-0,48	-0,21	-0,95	-0,37	-0,56	-0,06	-0,53
Ivanišević	-0,29	-0,07	-0,05	-0,50	0,00	-0,19	0,00	-0,24
Puljak	0,34	0,06	-0,03	-0,03	0,00	0,00	0,00	0,00
Zaninović	-0,06	-0,12	0,00	-0,59	0,00	-0,06	0,00	-0,06
Vidošević	-0,10	-0,10	0,00	-0,10	0,00	-0,20	0,00	0,00
Visković	-0,51	-0,12	0,02	-0,93	0,00	-0,23	0,00	0,00
Bilač	-0,20	-0,10	0,02	-0,85	0,00	-0,05	0,00	-0,05

Tablica 5. prikazuje rezultate dobivene za srednje vrijednosti SO komentara o kandidatima u kategorijama: Potpora, Sposobnost, Pristojnost, Moralnost, Odgovornost, Izgled, Domoljublje i Kriminalnost. U svim kategorijama, osim u kategoriji Domoljublje, Željko Kerum imao je najniže srednje vrijednosti SO komentara i one su sve bile negativne. U kategoriji Domoljublje najnižu srednju vrijednost SO komentara imao je Ivo Baldasar (-0,27) koji je i u svim drugim kategorijama imao negativne srednje vrijednosti SO komentara, osim u kategoriji Izgled o kojoj nije bilo komentara o njemu. Kategorija Domoljublje negativno je komentirana i kod Željka Keruma (-0,06). Marijana Puljak, u odnosu na ostale kandidate, imala je najvišu srednju vrijednost SO komentara u kategorijama Potpora (0,34) i Sposobnost (0,06), za koje je srednja vrijednost bila pozitivna te u kategoriji Moralnost za koju je srednja vrijednost bila negativna (-0,03). Sanja Bilač i Anđelka Visković, u odnosu na ostale kandidate, imale su najvišu srednju vrijednost SO komentara u kategoriji Izgled i ona je bila pozitivna (0,02). Moralnost je komentirana kod svih kandidata i za sve je kandidate srednja vrijednost SO komentara u ovoj kategoriji bila negativna, a najlošije su ocijenjeni Željko Kerum (-0,95) i Anđelka Visković (-0,93). O pristojnom ponašanju građani novinari najnegativnije su se izjašnjavali komentirajući Željka Keruma, za kojeg je srednja vrijednost SO komentara o pristojnosti bila -0,37, dok su prema Ivi Baldasaru bili blaži i za njega je srednja vrijednost SO komentara o pristojnosti bila -0,01. U kategoriji Kriminalnost dominirali su negativni komentari, a najlošije je bio ocijenjen Kerum za kojeg je srednja vrijednost SO komentara o kriminalnosti bila -0,53.



Graf 4. Prosječna SO komentara kojima se iskazuje potpora kandidatu na portalu 24 sata

Graf 4. prikazuje prosječne SO komentara u kategoriji Potpora iz kojeg se uočava da je najviše potpore dobila Marijana Puljak, a najmanje Željko Kerum.



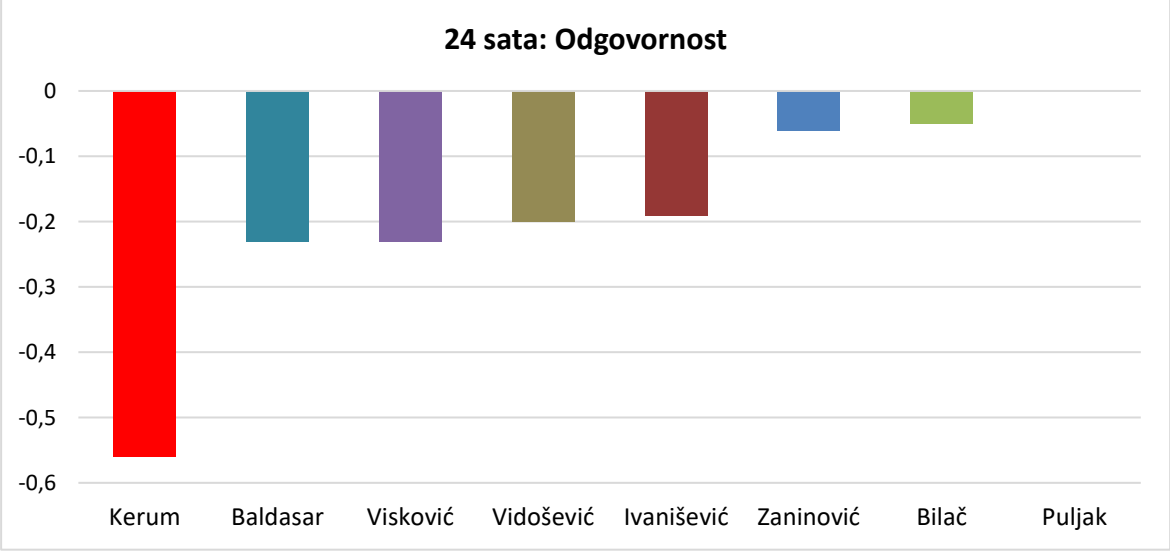
Graf 5. Prosječna SO komentara o sposobnosti kandidata na portalu 24 sata

Graf 5. prikazuje prosječne SO komentara u kategoriji Sposobnost iz kojeg se uočava da je najsposobnijom ocijenjena Marijana Puljak, a najmanje sposobnim Željko Kerum.



Graf 6. Prosječna SO komentara o pristojnosti kandidata na portalu 24 sata

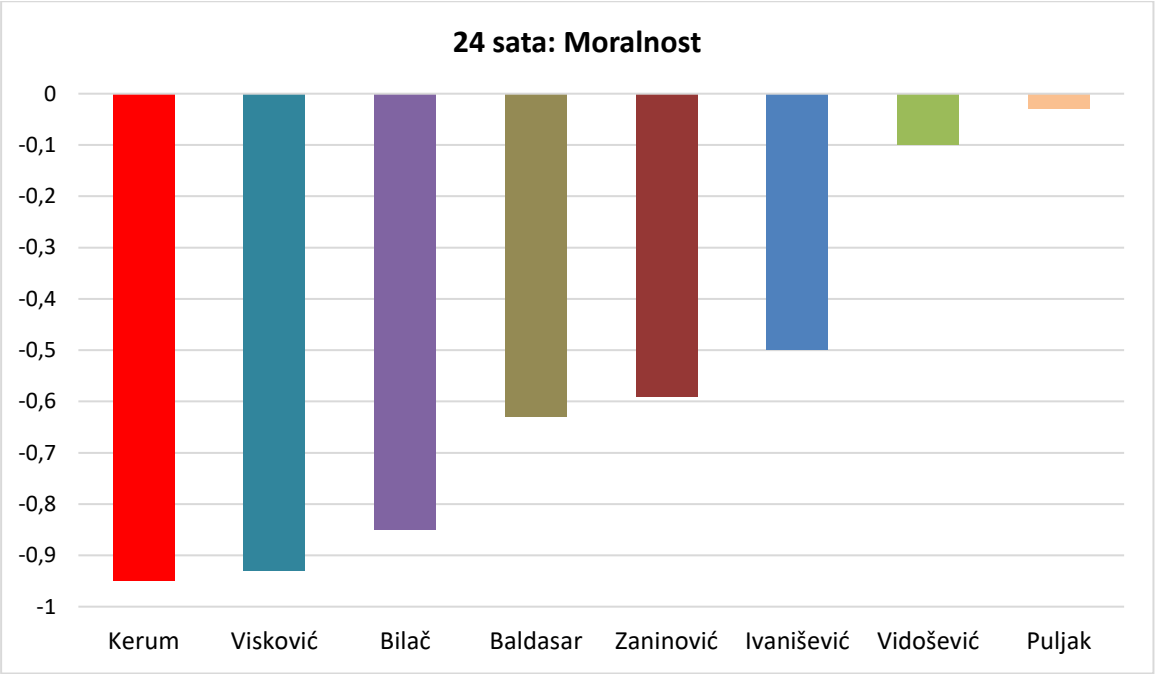
Graf 6. prikazuje prosječne SO komentara u kategoriji Pristojnost iz kojeg se uočava da je najmanje pristojnim ocijenjen Željko Kerum. Ivo Baldasar također je negativno komentiran, premda ima znatno nižu jakost negativnih komentara. Preostali kandidati u ovoj kategoriji nisu bili komentirani ili je srednja vrijednost SO komentara u toj kategoriji bila nula.



Graf 7. Prosječna SO komentara o odgovornosti kandidata na portalu 24 sata

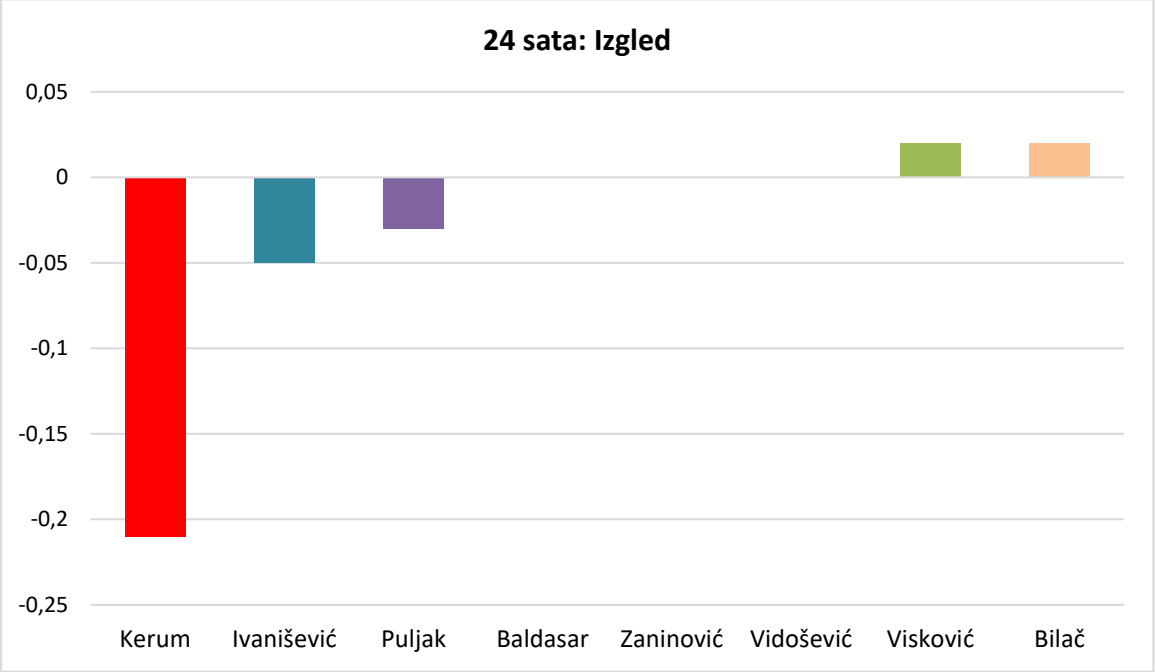
Graf 7. prikazuje prosječne SO komentara u kategoriji Odgovornost iz kojeg se uočava da je najmanje odgovornim ocijenjen Željko Kerum, a najpovoljniji rezultat u ovoj kategoriji

ima Sanja Bilač, premda je i za nju rezultat bio negativan. Marijana Puljak u ovoj se kategoriji nije komentirala.



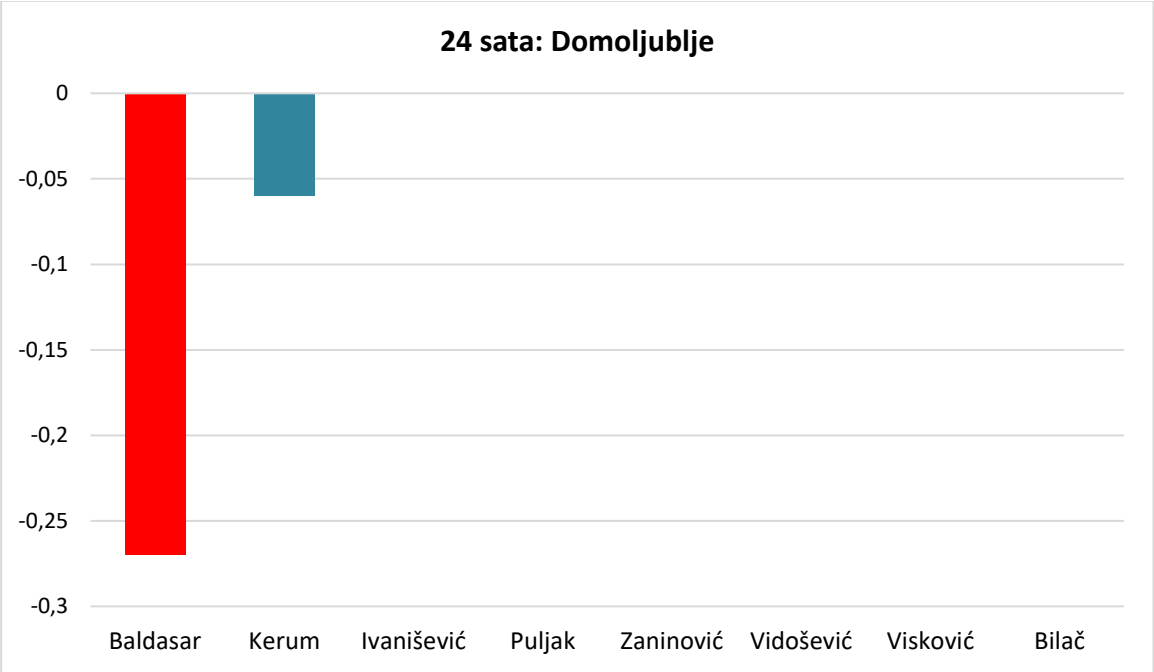
Graf 8. Prosječna SO komentara o moralnosti kandidata na portalu 24 sata

Graf 8. prikazuje prosječne SO komentara u kategoriji Moralnost iz kojeg se uočava da je najmanje moralnim ocijenjen Željko Kerum, a najbolji je rezultat, premda i dalje negativan, imala Marijana Puljak.



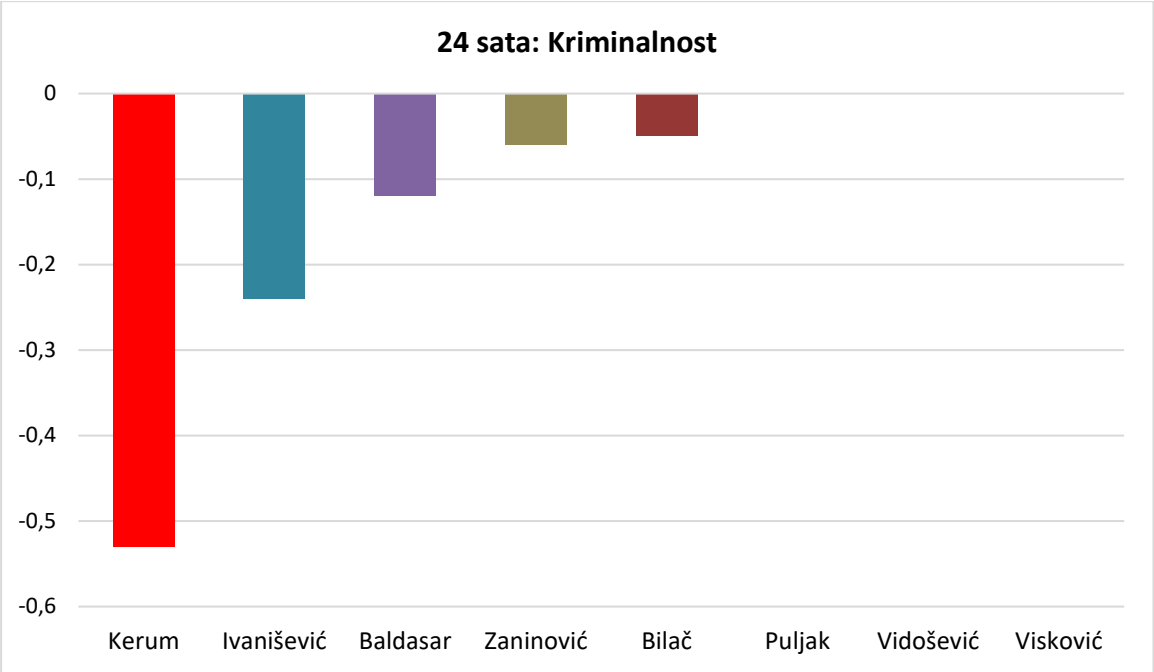
Graf 9. Prosječna SO komentara o izgledu kandidata na portalu 24 sata

Graf 9. prikazuje prosječne SO komentara u kategoriji Izgled iz kojeg se uočava da je u ovoj kategoriji najslabije ocijenjen Željko Kerum, a najbolje Sanja Bilač i Anđelka Visković, o kojima su dominirali pozitivni komentari. Negativno su ocijenjeni i kandidati Ivanišević i Puljak. Preostali kandidati u ovoj kategoriji nisu bili komentirani ili je ukupna SO komentara o njima s obzirom na ovu odliku bila nula.



Graf 10. Prosječna SO komentara o domoljublju kandidata na portalu 24 sata

Graf 10. prikazuje prosječne SO komentara u kategoriji Domoljublje iz kojeg se uočava da je u toj kategoriji najslabije ocijenjen Ivo Baldasar. Negativno je ocijenjen i Željko Kerum. Preostali kandidati u toj kategoriji nisu bili komentirani ili je ukupna SO komentara s obzirom na ovu odliku bila nula.



Graf 11. Prosječna SO komentara o kriminalnosti kandidata na portalu 24 sata

Graf 11. prikazuje prosječne SO komentara u kategoriji Kriminalnost iz kojeg se uočava da je u ovoj kategoriji najslabije ocijenjen Željko Kerum. Negativno su ocijenjeni i Vjekoslav Ivanišević, Ivo Baldasar, Tomislav Zaninović i Sanja Bilač. Preostali kandidati u ovoj kategoriji nisu bili komentirani ili je ukupna SO komentara o njima s obzirom na ovu odliku bila nula.

Analizom SO komentara, u odnosu na različite odlike kandidata, može se utvrditi da prevladavaju negativni stavovi, da su se građani novinari najviše negativno izražavali o kandidatima u kategoriji Moralnost i da nitko u toj kategoriji nije imao pretežito pozitivne stavove. Najviše negativnih stavova u svim kategorijama, osim u kategoriji Domoljublje, građani novinari imali su o Željku Kerumu. Najpozitivnije mišljenje gotovo u svim kategorijama građani novinari imali su o Marijani Puljak. Sanja Bilač i Anđelka Visković pretežito su pozitivne komentare dobile u kategoriji Izgled.

3.2.3. Odlike konverzacije

Tablica 6. Centralne vrijednosti razine polemičnosti, interaktivnosti i argumentiranosti na novinskom portalu 24 sata.

	a	i	r_p
Med	4,26%	42,58%	3,016
Mod	0,00%	33,33%	2,167
Mean	5,69%	41,19%	3,004

Tablica 6. prikazuje rezultate dobivene za centralne vrijednosti razine polemičnosti, argumentiranosti i interaktivnosti komentara na članke. Uočava se niska razina polemičnosti i argumentiranosti, dok je interaktivnost veća. Budući da se za razinu polemičnosti i argumentiranosti prema Shapiro-Wilkovu testu nisu dobile normalne raspodjele rezultata, kao bolji pokazatelj centralne vrijednosti za te varijable uzeo se medijan. Tako je medijan za razinu polemičnosti iznosio 3,016, a za argumentiranost 4,26 %. Raspodjela rezultata za interaktivnost imala je odlike normalne raspodjele, a srednja vrijednost za interaktivnost konverzacija iznosila je 41,19%. Niska razina polemičnosti, u odnosu na veću interaktivnost, može se objasniti konverzacijom u kojoj pojedini građani novinari ulaze u međusobne prepirke ili pohvale, zbog čega u dubljim slojevima konverzacija nema velikog broja građana novinara. Može se zaključiti da su na portalu 24 sata konverzacije o kandidatima za splitskog gradonačelnika imale nisku razinu javne rasprave, o čemu svjedoči niska razina polemičnosti i argumentiranosti.

3.2.4. Teme, sentimenti i polemičnost konverzacije

Tablica 7. Popis novinskih članaka i pripadajući postotak pozitivnih komentara o kandidatima

Tema	Pozitivni komentari
Kerum: Ustupanje Thompsonu stadiona	53,33%
Puljak: Otkrio je Božju česticu i sada se bori protiv Keruma u Splitu	50,00%
Kerum: Pjeva ustaške pjesme	45,00%
Kerum: Pjeva ustaške pjesme	34,52%
Kerum: Uništio i osramotio Split	31,82%
Ivanišević: Najava kandidature	31,58%
Kerum: Bonovi umirovljenicima i siromašnima	28,57%
Kerum: Afera vrtići	25,00%
Kerum: Vlast prodaje muda za bubrege	25,00%
Kerum: Pjeva ustaške pjesme	24,68%

Tablica 7. prikazuje popis prvih 10 novinskih članaka s obzirom na postotak pozitivnih komentara o kandidatima. Najviše pozitivnih komentara dobio je članak o Željku Kerumu i ustupanju gradskog stadiona za koncert Thompsonu (53,33%), zatim o Marijani Puljak i najavi njezine liste za gradsko vijeće (50%) te o Željku Kerumu i pjevanju ustaških pjesama (45%).

Tablica 8. Popis novinskih članaka i pripadajući postotak negativnih komentara o kandidatima

Tema	Negativni komentari
Baldasar: Milanović na stranačkom skupu suparnicima slao puse	100,00%
Kerum: Koncesija kafića na Zapadnoj obali	100,00%
Bilač: Najavila kandidaturu: Kod mene neće biti foteljaša	96,77%
Kerum: Nije podnio izviješće o radu, sjednicu gledao na TV	96,67%
Visković: Za minutu 'riješila' Rubikovu kocku, tako će i Split	96,55%
Kerum: Izgorjela arhiva tvrtke Kerum	96,55%
Kerum: Dugovanje plaća radnicima	95,45%
Kerum: Političari poput mene ne postoje	95,38%
Kerum: Fanino parkiranje	95,00%
Kerum: Najavio govor u saboru	94,92%

Tablica 8. prikazuje popis prvih 10 novinskih članaka s obzirom na postotak negativnih komentara. Najviše negativnih komentara bilo je o Ivi Baldasaru i predizbornom skupu SDPa u Splitu te o Željku Kerumu i davanju koncesije za kafić na Zapadnoj obali bratu Kerumove izvanbračne partnerice Fani (100%).

Tablica 9. Popis novinskih članaka i razina polemičnosti konverzacija

Tema	r_p
Kerum: Donacija redovnicama	7,005
Kerum: Spomenik Tuđmanu	6,003
Kerum: Optuživanje Grubišića	6,003
Kerum: Najava govora u Saboru na radio Splitu	5,006
Kerum: Pršut na čelu	5,003
Baldasar: Preuredit ću Split i pomesti Kerumove direktore	4,017
Kerum: Pomaganje mi je u genima	4,013
Kerum: Podizanje spomenika Tuđmanu	4,012
Kerum: Cijelo sam selo stavio u školske odbore (ironija)	4,012
Kerum: Križ na Marjanu	4,009

Tablica 9. prikazuje popis prvih 10 novinskih članaka s obzirom na razinu polemičnosti. Najveću razinu polemičnosti imali su članci o Kerumovoj donaciji splitskim redovnicama (7,005), podizanju spomenika Franji Tuđmanu (6,003) i optuživanju don Ivana Grubišića (6,003).

3.3. Portal Indeks

Obrađeno je ukupno 3115 komentara napisanih na 99 novinskih članaka o kandidatima za splitskog gradonačelnika. Od toga se 2415 komentara odnosilo na kandidate, a 525 na građane novinare.

3.3.1. Analiza sentimenata

Tablica 10. SO komentara na portalu Index

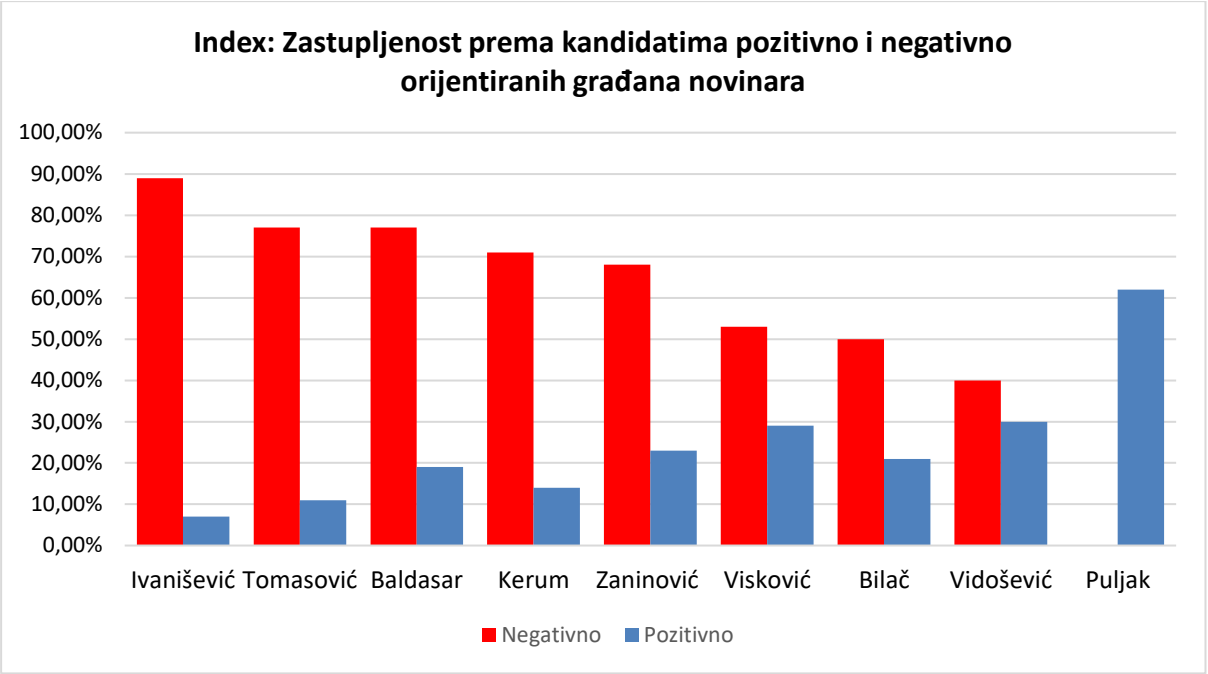
	Br. čl	Br. kom.	Br. gr. n.	Avg SO	Med SO	Mod SO	Max	Min	Poz	Neg	Neu
Kerum	69	2995	814	-4,21	-1	-1	48	-109	14%	71%	15%
Baldasar	1	195	124	-1,90	-1	-1	16	-14	19%	77%	4%
Visković	3	91	57	-0,53	-1	-1	3	-3	29%	53%	18%
Ivanišević	3	113	75	-2,53	-2	-1	1	-13	7%	89%	4%
Bilač	3	28	24	-0,79	-0,5	-1	1	-6	21%	50%	29%
Puljak	2	9	8	1,50	1	1	7	0	62%	0%	38%
Zaninović	3	39	34	-0,76	-1	-1	7	-6	23%	68%	9%
Vidošević	1	8	8	-0,70	0	0	1	-6	30%	40%	30%
Tomasović	1	30	26	-0,73	-1	-1	8	-4	11%	77%	12%
Građani n.		525	217	-2,41	-1	-1	3	-26	10%	87%	3%

Tablica 10. prikazuje rezultate dobivene za centralne vrijednosti SO komentara o svakom kandidatu komentiranom na novinskom portalu Index, za broj napisanih članaka o kandidatu, za broj komentara o kandidatu i za broj građana novinara koji su komentirali kandidata. Uočava se da je najveći udio građana novinara s pozitivnim komentarima bio za kandidatkinju Marijanu Puljak (62%), a najmanje za kandidata Vjekoslava Ivaniševića (7 %). Za kandidata Ivaniševića najveći je udio građana novinara napisao negativne komentare (89%), pa se može zaključiti da je on na dnu ljestvice kojom se mjeri naklonost građana novinara prema pojedinim kandidatima. Na isti bi se način za Marijanu Puljak moglo ustvrditi da je na vrhu te ljestvice, budući da uz najveći udio građana novinara koji su se o njoj pozitivno izjašnjavali uopće nije bilo građana novinara koji su se o njoj negativno izjašnjavali (0%), a sve tri centralne vrijednosti za SO komentara o njoj su bile pozitivne ili neutralne. Međutim, ovi rezultati nemaju

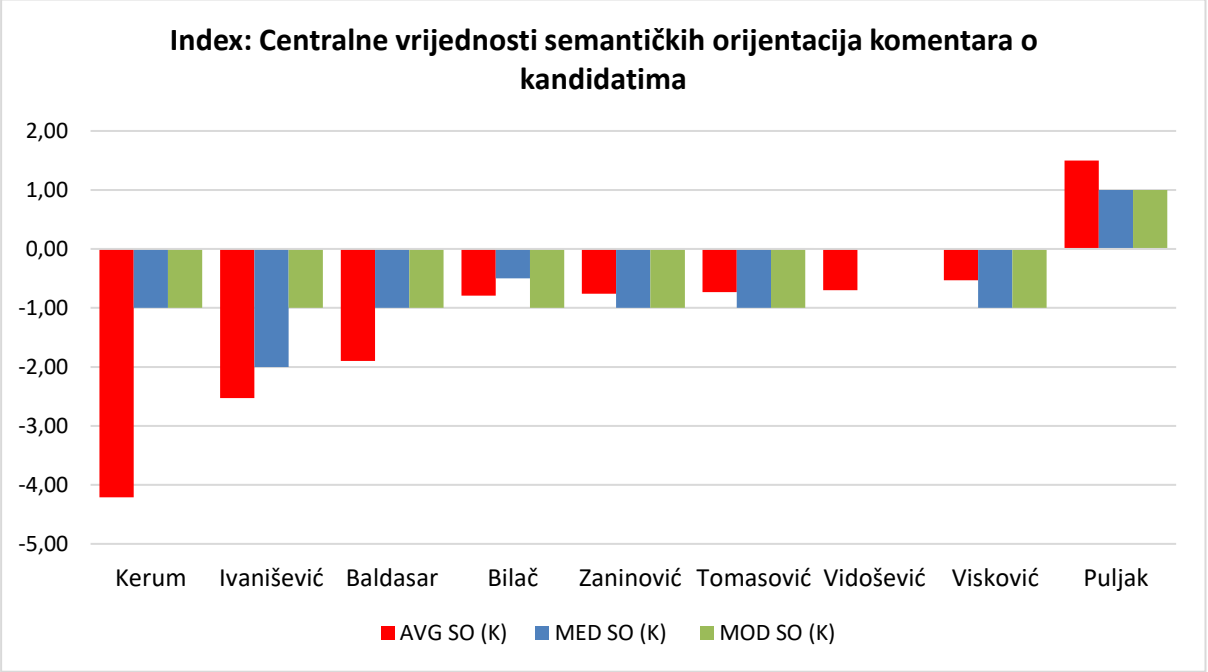
veliku statističku važnost, budući da se o kandidatkinji Puljak izjasnilo svega 8 građana novinara. Na portalu Index, nakon Marijane Puljak, najviše građana novinara pozitivno je komentiralo Damira Vidoševića (30%) i Anđelku Visković (29%). Ako se ponovo uzme u obzir mali broj građana novinara koji su komentirali Damira Vidoševića, zbog čega rezultati nemaju dovoljnu statističku važnost, tada bi se moglo zaključiti da je na portalu Index najpozitivnije ocijenjena Anđelka Visković o kojoj se otprilike trećina građana novinara izjašnjavala pozitivno, a polovica negativno (53%). Nakon nje slijedi Sanja Bilač o kojoj se 21 % građana novinara izjasnilo pozitivno, a polovica negativno (50%).

Srednje vrijednosti SO komentara osjetljive su na izrazito negativne ili pozitivne SO komentara pojedinih građana novinara, što se i na ovom portalu najbolje vidi na primjeru Željka Keruma za kojeg je srednja vrijednost ukupne SO komentara iznosila -4.21, a medijan -1. Iz toga se može zaključiti da su pojedini građani novinari imali izrazito negativne komentare o kandidatu Željku Kerumu. Nešto veća razlika između medijana i srednje vrijednosti SO komentara uočava se i kod Ive Baldasara. U njegovom slučaju srednja vrijednost SO komentara bila je -1,9, a medijan -1, pa bi se i ovdje moglo govoriti o postojanju građana novinara s izrazitijim negativnim komentarima. No, velika razlika između medijana i srednje vrijednosti SO komentara o Željku Kerumu upućuje na zaključak da su određeni građani novinari na portalu Index iskazivali o njemu izrazito negativne stavove. Tako je ukupna SO komentara građanina novinara koji je imao najnegativnije komentare o Željku Kerumu iznosila – 109, a ukupna SO komentara građanina novinara koji je o njemu imao najpozitivnije komentare iznoslila je 48.

SO komentara koji su se odnosili na građane novinare bile su pretežito negativne. 87 % građana novinara imalo je negativne komentare o drugim građanima novinarima, 10 % pozitivne, a 3 % neutralne. Centralne vrijednosti ukupnih SO komentara koji su se odnosili na građane novinare bile su također negativne. Srednja vrijednost iznosila je – 2,41, dok su medijan i mod iznosili -1. Velika razlika između medijana i srednje vrijednosti i ovdje upućuje na zaključak da su pojedini građani novinari imali izrazito negativne komentare o drugim građanima novinarima.



Graf 12. Zastupljenost građana novinara koji su se negativno i pozitivno izjasnili o kandidatima na portalu Index



Graf 13. Centralne vrijednosti SO komentara o kandidatima na portalu Index

Graf 12. prikazuje udio građana novinara koji su se pozitivno i negativno izjasnili o kandidatima na novinskom portalu Index, a graf 13. centralne vrijednosti SO komentara o kandidatima na tom portalu. Može se zaključiti da su stavovi građana novinara o svim kandidatima bili pretežito negativni, osim za Marijanu Puljak.

Tablica 11. Rezultati Shapiro-Wilkovog testa normalnosti raspodjele rezultata na novinskom portalu Index

	W	p-value	alpha	normal
SO(Ker)	0,51	0,000	0,05	no
SO(Bil)	0,84	0,002	0,05	no
SO (Bal)	0,85	0,000	0,05	no
SO (S)	0,32	0,000	0,05	no
a	0,44	0,000	0,05	no
i	0,96	0,003	0,05	no
rp	0,78	0,000	0,05	no

U tablici 11. prikazani su rezultati testiranja normalnosti raspodjele rezultata pomoću Shapiro – Wilkovog testa za SO komentara kandidata koje je na istraživanim portalima komentiralo barem 20 građana novinara te za razinu polemičnosti, interaktivnosti i argumentiranosti. Može se zaključiti da raspodjele rezultata za ukupne SO komentara, razine polemičnosti, interaktivnosti i argumentiranosti nisu imale odlike normalne distribucije.

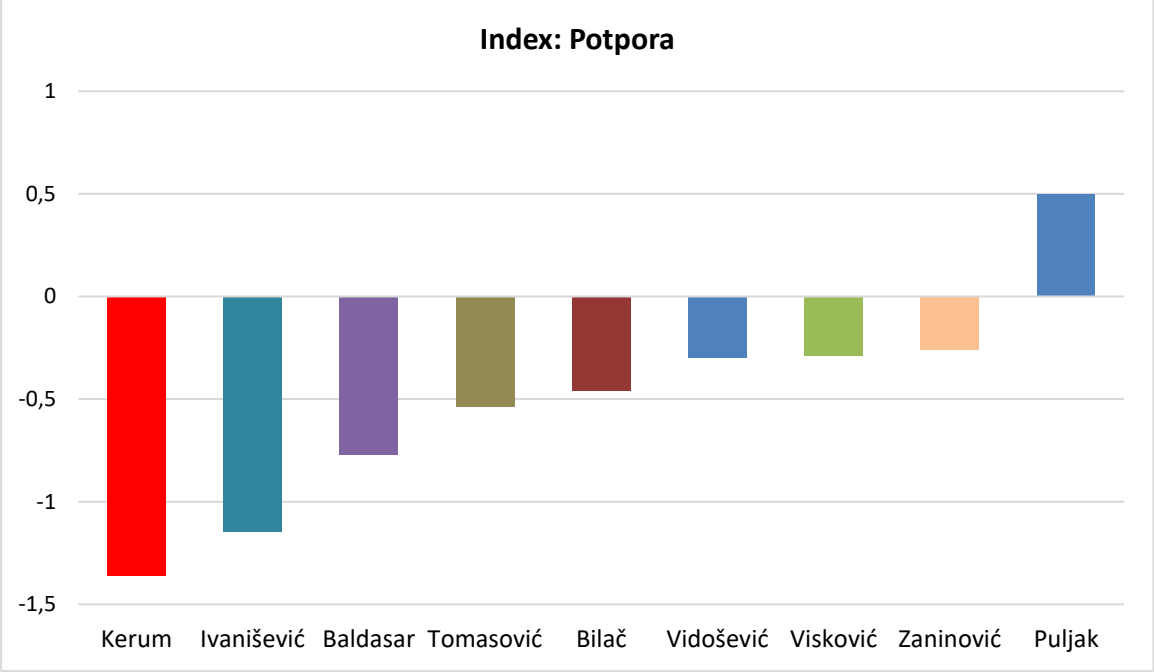
3.3.2. Odlike kandidata

Tablica 12. Prosječne vrijednosti SO komentara u odnosu na odlike kandidata

	PO	SP	PR	OD	MO	IZ	DO	KR
Kerum	-1,36	-0,33	-0,63	-0,33	-0,92	-0,12	-0,07	-0,47
Zaninović	-0,26	-0,09	-0,15	-0,03	-0,12	0,00	0,00	-0,15
Visković	-0,29	-0,06	0,00	0,00	-0,18	0,00	0,00	0,00
Vidošević	-0,30	-0,10	0,00	0,00	-0,30	0,00	0,00	0,00
Tomasović	-0,54	-0,04	-0,04	-0,04	-0,12	-0,08	0,12	0,00
Baldasar	-0,77	-0,13	-0,06	-0,09	-0,56	-0,02	-0,10	-0,17
Bilač	-0,46	-0,04	0,00	0,00	-0,25	0,04	0,00	-0,08
Ivanišević	-1,15	-0,09	-0,09	-0,15	-0,39	-0,01	0,00	-0,65
Puljak	0,50	0,38	0,13	0,25	0,25	0,00	0,00	0,00

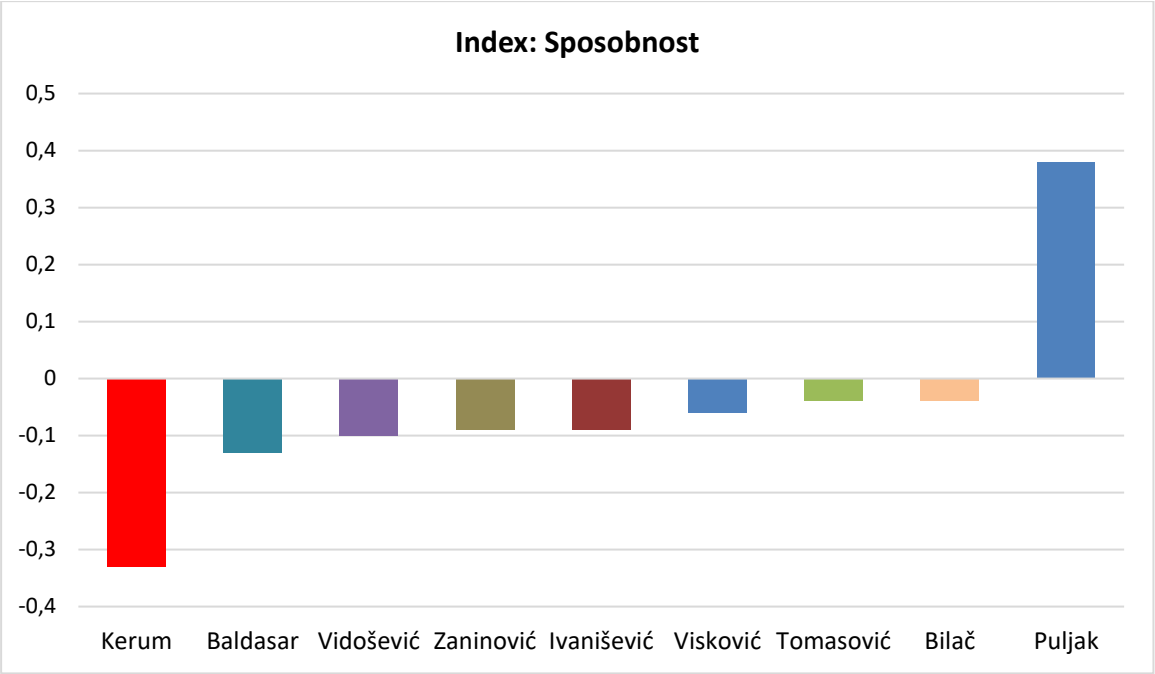
Tablica 12. prikazuje rezultate dobivene za srednje vrijednosti SO komentara u kategorijama: Potpora, Sposobnost, Pristojnost, Moralnost, Odgovornost, Izgled, Domoljublje i Kriminalnost. U svim kategorijama, osim u kategoriji Domoljublje i Kriminalnost, Željko Kerum imao je najniže srednje vrijednosti SO komentara i one su sve bile negativne. U kategoriji Domoljublje najnižu srednju vrijednost SO komentara imao je Ivo Baldasar (-0,10) koji je i u svim drugim kategorijama imao negativne srednje vrijednosti SO komentara.

Marijana Puljak imala je najvišu srednju vrijednost SO komentara u svim kategorijama, osim u kategoriji Domoljublje, Izgled i Kriminalnost o kojima nije bila komentirana. Međutim, treba ponovo uzeti u obzir mali broj građana novinara koji su komentirali Marijanu Puljak (8), tako da ovi rezultati nemaju dovoljnu statističku važnost. Sanja Bilač imala je najvišu srednju vrijednost SO komentara u kategoriji Izgled i ona je bila pozitivna (0,04), dok je u ostalim kategorijama srednja vrijednost SO komentara o njoj bila negativna ili u tim kategorijama ona nije bila komentirana. Kategorija Domoljublje komentirana je kod kandidata Ive Baldasara, Željka Keruma i Hrvoja Tomasovića. Tomasović je jedini imao pozitivnu srednju vrijednost ukupne SO komentara o domoljublju (0,12). Moralnost je komentirana kod svih kandidata i za sve je kandidate, osim za Marijanu Puljak, srednja vrijednost SO komentara u ovoj kategoriji bila negativna. I u kategoriji Pristojnost svi su komentirani kandidati imali srednje vrijednosti SO komentara negativne. U kategoriji Kriminalnost najlošiji rezultat imao je Vjekoslav Ivanišević (-0,65), zatim Željko Kerum (-0,47), Ivo Baldasar (-0,17), Tomislav Zaninović (-0,15) i naposljetku Sanja Bilač (-0,08).



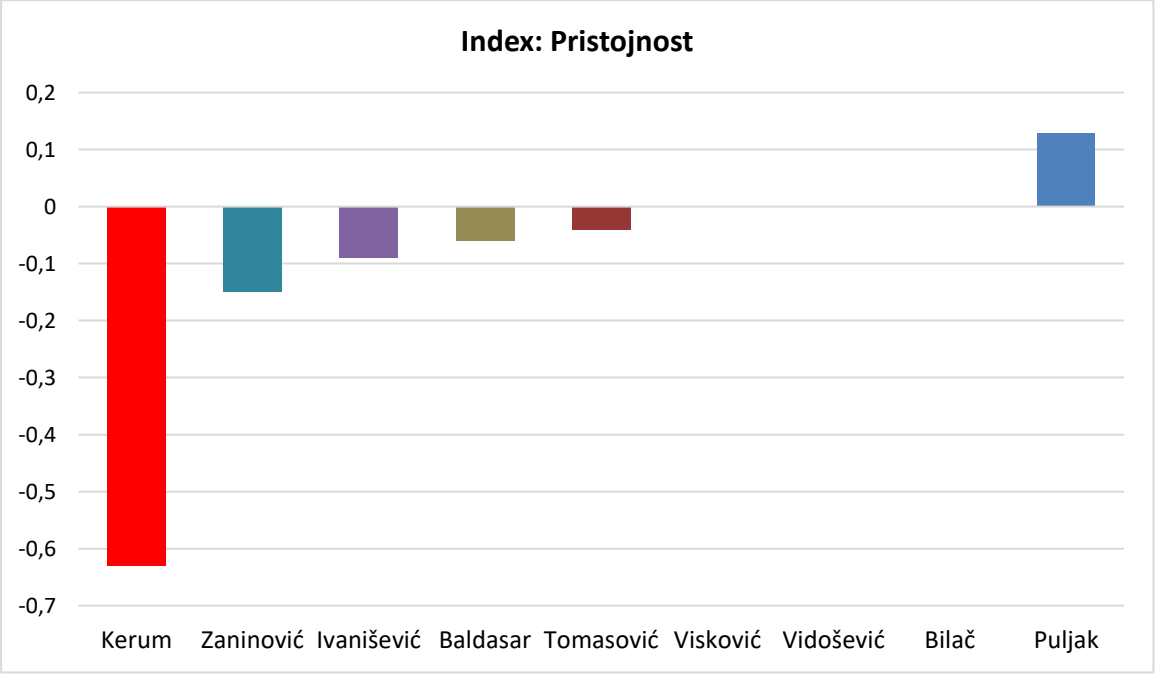
Graf 14. Prosječna SO komentara kojima se iskazuje potpora kandidatu na portalu Index

Graf 14. prikazuje prosječne SO komentara u kategoriji Potpora iz kojeg se uočava da je u ovoj kategoriji najslabije ocijenjen Željko Kerum. Negativno su ocijenjeni svi kandidati osim Marijane Puljak.



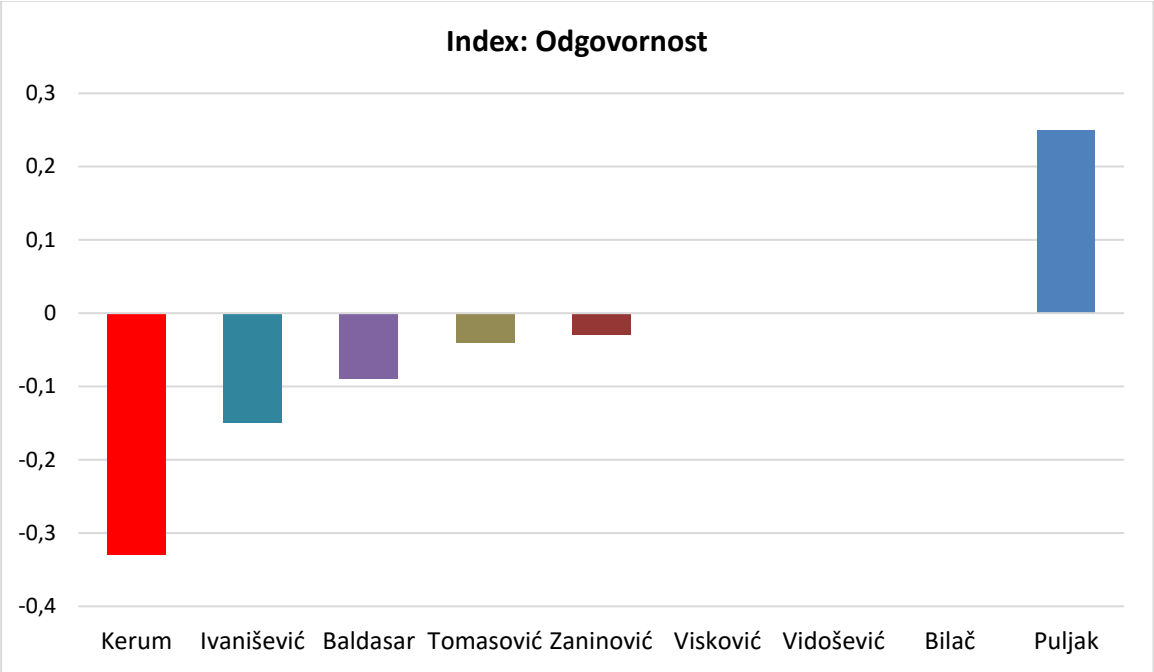
Graf 15. Prosječna SO komentara o sposobnosti kandidata na portalu Index

Graf 15. prikazuje prosječne SO komentara u kategoriji Sposobnost. Uočava se da je u toj kategoriji najslabije ocijenjen Željko Kerum, a jedina pozitivno i najbolje ocijenjena je Marijana Puljak.



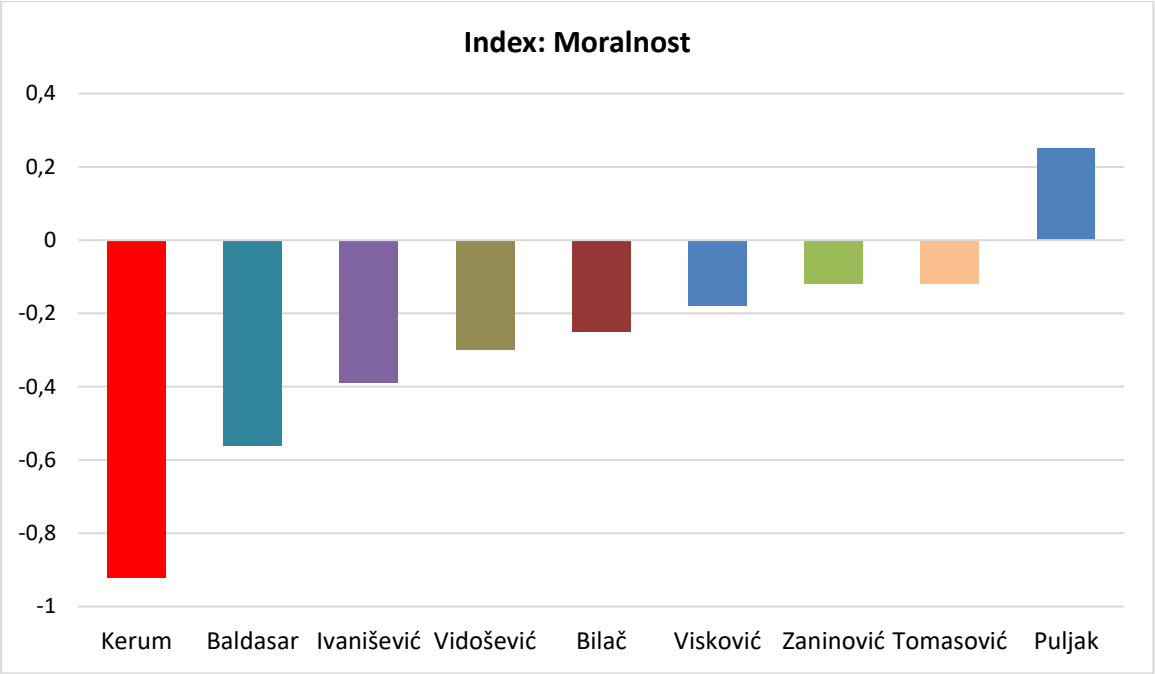
Graf 16. Prosječna SO komentara o pristojnosti kandidata na portalu Index

Graf 16. prikazuje prosječne SO komentara u kategoriji Pristojnost. Uočava se da je u toj kategoriji najslabije ocijenjen Željko Kerum, zatim Tomislav Zaninović, Vjekoslav Ivanišević, Ivo Baldasar i Hrvoje Tomasović, a jedina je pozitivno i najbolje ocijenjena Marijana Puljak. Preostali kandidati u toj kategoriji nisu bili komentirani ili je ukupna SO komentara s obzirom na ovu odliku bila nula.



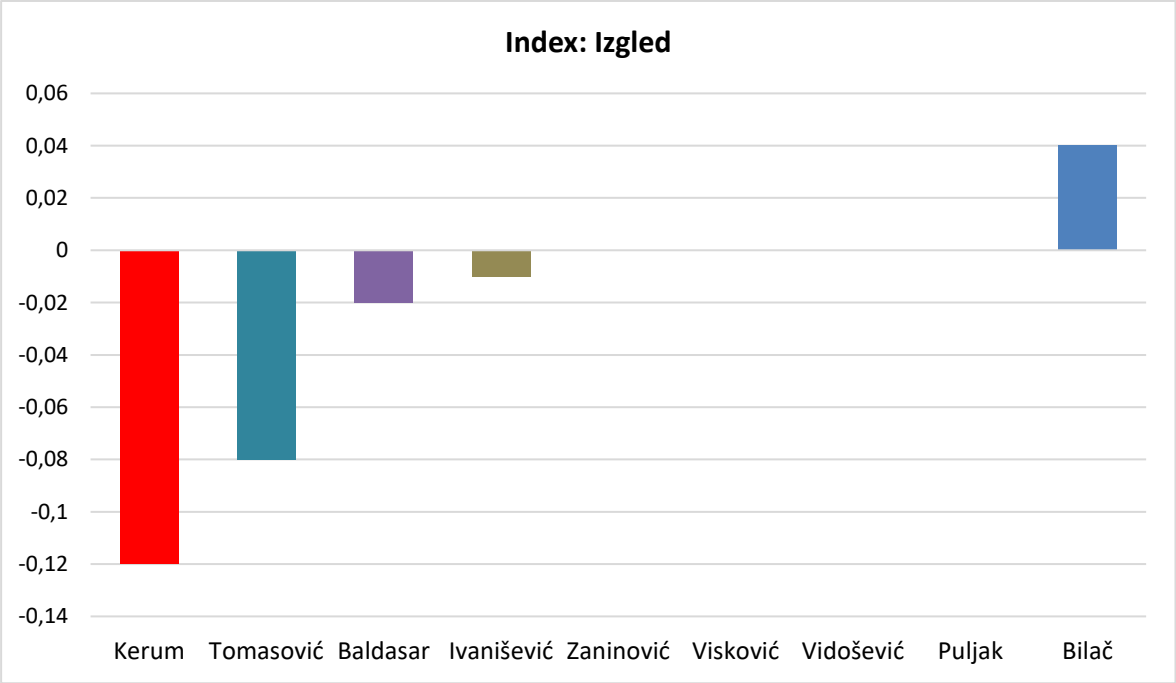
Graf 17. Prosječna SO komentara o odgovornosti kandidata na portalu Index

Graf 17. prikazuje prosječne SO komentara u kategoriji Odgovornost. Uočava se da je u toj kategoriji najslabije ocijenjen Željko Kerum, zatim Vjekolsav Ivanišević, Ivo Baldasar, Hrvoje Tomasović i Tomislav Zaninović, a jedina je pozitivno i najbolje ocijenjena Marijana Puljak. Preostali kandidati u toj kategoriji nisu bili komentirani ili je ukupna SO komentara s obzirom na ovu odliku bila nula.



Graf 18. Prosječna SO komentara o moralnosti kandidata na portalu Index

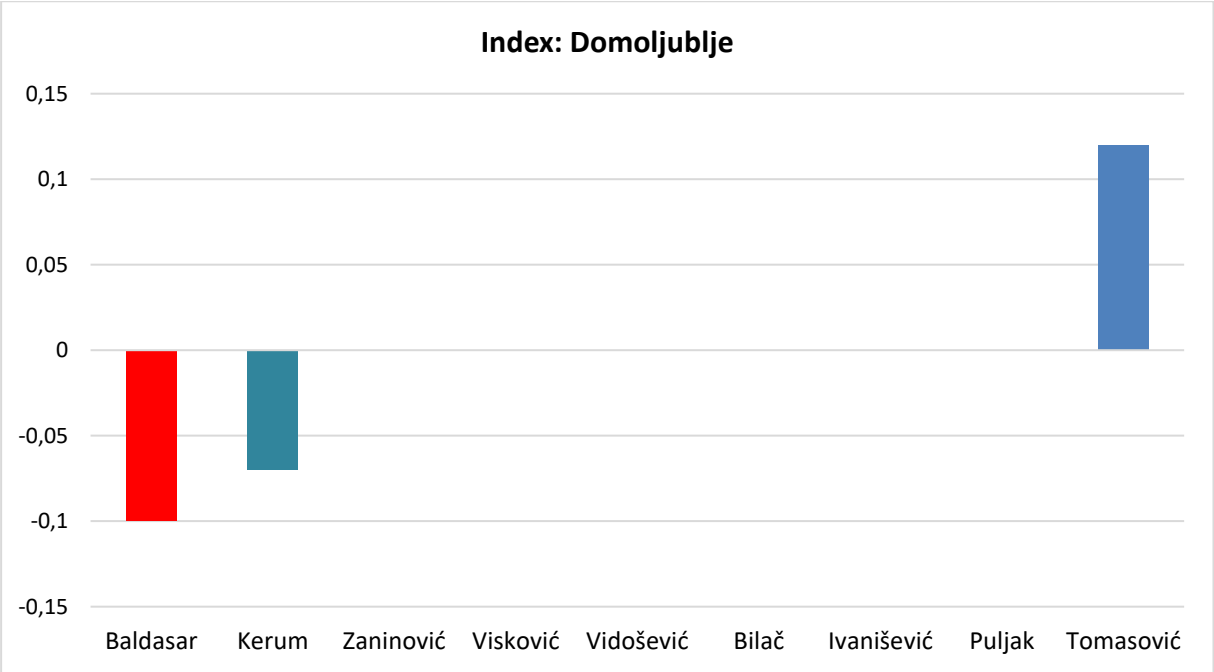
Graf 18. prikazuje prosječne SO komentara u kategoriji Moralnost. U toj je kategoriji najslabije ocijenjen Željko Kerum, a jedina je pozitivno i najbolje ocijenjena Marijana Puljak.



Graf 19. Prosječna SO komentara o izgledu kandidata na portalu Index

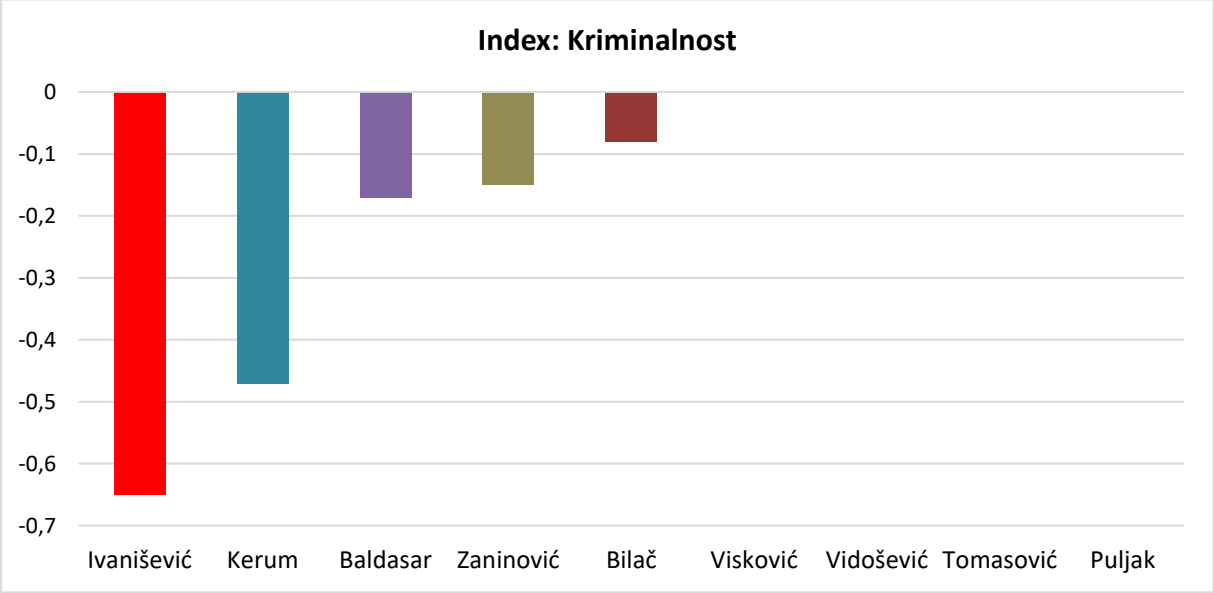
Graf 19. prikazuje prosječne SO komentara u kategoriji Izgled. U toj je kategoriji najslabije ocijenjen Željko Kerum, zatim Hrvoje Tomasović, Ivo Baldasar i Vjekoslav

Ivanišević, a jedina je pozitivno i najbolje ocijenjena Sanja Bilač. Preostali kandidati u toj kategoriji nisu bili komentirani ili je ukupna SO komentara s obzirom na ovu odliku bila nula.



Graf 20. Prosječna SO komentara o domoljublju kandidata na portalu Index

Graf 20. prikazuje prosječne SO komentara u kategoriji Domoljublje. U toj je kategoriji najslabije ocijenjen Ivo Baldasar, a nakon njega Željko Kerum. Pozitivno je ocijenjen jedino Hrvoje Tomasović. Preostali kandidati u toj kategoriji nisu bili komentirani ili je ukupna SO komentara s obzirom na ovu odliku bila nula.



Graf 21. Prosječna SO komentara o kriminalnosti kandidata na portalu Index

Graf 21. prikazuje prosječne SO komentara u kategoriji Kriminalnost. U toj je kategoriji najslabije ocijenjen Vjekoslav Ivanišević, a nakon njega Željko Kerum, Ivo Baldasar, Tomislav Zaninović i Sanja Bilač. Preostali kandidati u toj kategoriji nisu bili komentirani ili je ukupna SO komentara o njima s obzirom na ovu odliku bila nula.

Analizom SO komentara, u odnosu na različite odlike kandidata, može se utvrditi da prevladavaju negativni stavovi, da su se građani novinari najviše negativno izražavali o kandidatima u kategoriji Moralnost. Najviše negativnih stavova u svim kategorijama, osim u kategoriji Domoljublje i Kriminalnost, građani novinari imali su o Željku Kerumu. Marijana Puljak u većini kategorija imala je pozitivne srednje vrijednosti SO, ali zbog malog broja građana novinara koji su se o njoj izjašnjavali taj rezultat nema dovoljnu statističku važnost.

3.3.3. Odlike konverzacije

Tablica 13. Centralne vrijednosti razine polemičnosti, interaktivnosti i argumentiranosti na novinskom portalu Index.

	a	i	rp
Med	0,00%	27,45%	2,071
Mod	0,00%	0,00%	2,091
Mean	5,130%	29,53%	2,385

Tablica 13. prikazuje rezultate dobivene za centralne vrijednosti razine polemičnosti, argumentiranosti i interaktivnosti konverzacija na članke, gdje je broj mjerenja jednak broju objavljenih članaka. Medijan za interaktivnost iznosio je 27,45%, za argumentiranost 0%, a za razinu polemičnosti 2,071. Niska razina polemičnosti i argumentiranosti upućuje na zaključak da je na portalu Index komunikacija građana novinara imala odlike niske razine javne rasprave. Nešto veća interaktivnost može se povezati sa prepirkama ili pohvalama među pojedinim građanima novinarima, zbog čega u dubljim slojevima konverzacije nije sudjelovao veći broj građana novinara.

3.3.4. Teme, sentimenti i polemičnost konverzacije

Tablica 14. Popis novinskih članaka i pripadajući postotak pozitivnih komentara o kandidatima na novinskom portalu Index

Tema	Pozitivni
Kerum: Tko zapravo plaća križ na Marjanu?	39,29%
Zaninović: ne bih sudjelovao u Gay prideu	33,33%
Baldasar: Ministarske limuzine na skupu podrške Baldasaru	31,58%
Kerum: ima za kampanju, nema za vjerovnike	29,69%
Kerum: križ i spomenik Tuđmanu	29,41%
Kerum: Otvaranje zapadne obale	28,33%
Kerum: dao Thompsonu stadion	28,32%
Kerum: dobio mjesto za plakatiranje	27,78%
Kerum: političari poput mene u Hrvatskoj ne postoje	25,71%
Kerum: gradit će se križ i spomenik Tuđmanu	23,33%

Tablica 14. prikazuje popis novinskih članaka s najvećim postotkom pozitivnih komentara o kandidatima. Članak s najviše pozitivnih komentara bio je o Željku Kerumu i križu na Marjanu (39,29) te o Tomislavu Zaninoviću i gay paradi (33,33%).

Tablica 15. Popis novinskih članaka i pripadajući postotak negativnih komentara o kandidatima na novinskom portalu Index

Tema	Negativni komentari
Kerum: Peticija protiv spomenika Tuđmanu	100,00%
Kerum: kadrovi za splitske škole	95,00%
Kerum: sestra ga hvali da je grad postao tako turistički uspješan zbog njega	92,59%
Kerum parkira na mjestu za invalide	92,59%
Kerum: peticija protiv spomenika	91,67%
Kerum: osuđen za aferu vrtići	89,19%
Kerum: zapošljavanje nećakinje u vodovodu	89,19%
Kerum plakati	88,89%
Kerum: križ	88,06%
Kerum: diže Tuđmana i križ, a državi ostavio dugove	87,04%

Tablica 15. Prikazuje popis novinskih članaka s najvećim postotkom negativnih komentara. Najviše negativnih komentara imao je članak o Željku Kerumu i podizanju spomenika Tuđmanu (100%) te o Kerumovu kadroviranju u nadzornim odborima splitskih osnovnih škola (95%).

Tablica 16. Popis novinskih članaka i pripadajuća razina polemičnosti na novinskom portalu Index

Tema	Rp
Kerum: Ustupanje Thompsonu stadiona	8,005
Kerum: Križ i spomenik Tuđmanu	6,006
Kerum: Splite, jesi spreman za još 4 godine Keruma?	5,011
Kerum: Otvaranje Zapadne obale	5,010
Zajedničko: Povijest se ponavlja: HDZ-ovci šokirani listom, glasat će za Keruma!	5,006
Kerum: Pjeva ustaške pjesme	5,005
Kerum: Državni vrh ignorira Zapadnu obalu	4,037
Kerum: Gradit će se križ i spomenik Tuđmanu	4,023
Kerum: A tko će čistiti nakon otvaranja Zapadne obale?	4,021
Kerum: Tko zapravo plaća križ na Marjanu?	4,017

Tablica 16. prikazuje popis novinskih članaka s najvećom razinom polemičnosti. Najvišu razinu polemičnosti u konverzaciji građana novinara postigao je novinski članak o Kerumovu ustupanju gradskog stadiona Thompsonu (8,005) te onaj o podizanju spomenika Tuđmanu i križa na Marjanu (6,006).

3.4. T-portal

Obrađeno je ukupno 786 komentara napisanih na 30 novinskih članaka o kandidatima za splitskog gradonačelnika. Od toga se 559 komentara odnosilo na kandidate, a 154 na građane novinare.

3.4.1. Analiza sentimenata

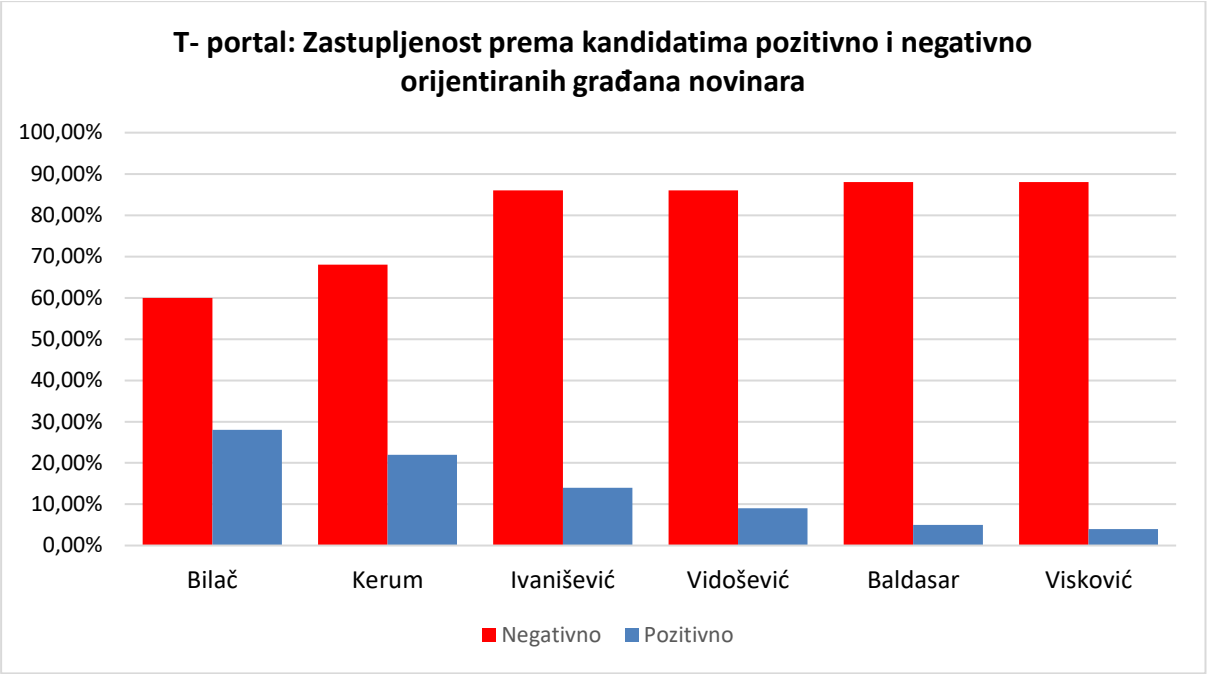
Tablica 17. SO komentara na T-portalu

	Br. čl	Br. Kom.	Br. gr. n.	Avg SO	Med SO	Mod SO	Max	Min	Poz	Neg	Neu
Kerum	16	514	312	-1,83	-1	-1	28	-43	22%	68%	10%
Baldasar	3	48	41	-1.98	-1	-1	2	-11	5%	88%	7%
Visković	2	34	26	-1,68	-1	-1	1	-7	4%	88%	8%
Ivanišević	1	16	14	-2.08	-1	-1	2	-15	14%	86%	0%
Bilač	5	56	43	-0.71	-1	-1	11	-9	28%	60%	12%
Vidošević	1	23	21	-1,35	-1	-1	3	-4	9%	86%	5%
Građani n.		154	70	-1,80	-1	-0	3	-19	16%	55%	29%

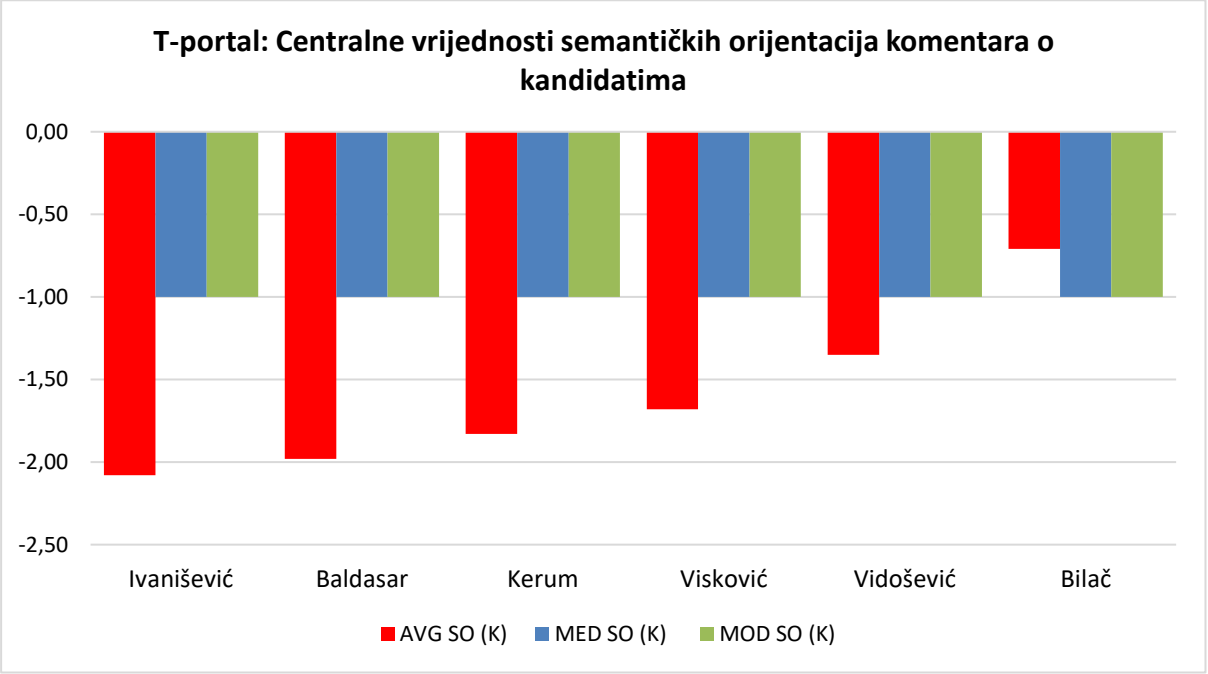
Tablica 17. prikazuje rezultate dobivene za centralne vrijednosti SO za svakog kandidata komentiranog na novinskom portalu Index, broj napisanih članaka o kandidatu, broj komentara o kandidatu i broj građana novinara koji su komentirali kandidata. Vidljivo je da je najviše građana novinara s pozitivnim komentarima imala kandidatkinja Sanja Bilač (62%), a najmanje kandidatkinja Anđelka Visković (4 %) i Ivo Baldasar (5%). Najviše građana novinara negativno se izjašnjavalo o Ivi Baldasaru (88%) i o Anđelki Visković (88%), pa se može zaključiti da su oni na dnu ljestvice kojom se mjeri naklonost građana novinara pojedinim kandidatima. Na isti način za Sanju Bilač moglo bi se ustvrditi da je na vrhu te ljestvice, budući da je uz najveći udio građana novinara koji su se o njoj pozitivno izjašnjavali imala najmanji udio građana novinara koji su se o njoj negativno izjašnjavali (60%), a srednja vrijednost za SO komentara o njoj je najviša (-0,71). Na T-portalu, nakon Sanje Bilač, najviše građana novinara s pozitivnim komentarima imao je Željko Kerum (28%), a potom Vjekoslav Ivanišević (14%).

Srednje vrijednosti SO komentara osjetljive su na izrazito negativne ili pozitivne SO komentara pojedinih građana novinara, što se na ovom portalu najviše uočava kod Vjekoslava Ivaniševića, za kojeg je srednja vrijednost ukupne SO komentara građana novinara iznosila -2,08, a medijan -1. No, slična razlika između medijana i srednje vrijednosti uočava se i kod Željka Keruma i Ive Baldasara. Iz toga se može zaključiti da su pojedini građani novinari imali izrazito negativne komentare o spomenutim kandidatima. Tako je ukupna SO komentara građana novinara koji je imao najnegativnije komentare o Vjekoslavu Ivaniševiću iznosila – 15, a ukupna SO komentara građana novinara koji je o njemu imao najpozitivnije komentare 2.

SO komentara koji su se odnosili na građane novinare bile su pretežito negativne. 55 % građana novinara imalo je negativne komentare o drugim građanima novinarima, 16% pozitivne, a 29 % neutralne. Centralne vrijednosti ukupnih SO komentara o građanima novinarima bile su negativne ili neutralne. Srednja vrijednost iznosila je – 1,8, medijan -1, a mod 0. Veća razlika između medijana i srednje vrijednosti i ovdje upućuje na zaključak da su pojedini građani novinari imali izrazito negativne komentare o drugim građanima novinarima.



Graf 22. Udio građana novinara koji su se negativno i pozitivno izjasnili o kandidatima na T-portalu



Graf 23. Centralne vrijednosti SO komentara o kandidatima na T- portalu

Graf 22. prikazuje udio građana novinara koji su se pozitivno i negativno izjasnili o kandidatima na T-portalu, a graf 23. centralne vrijednosti ukupnih SO komentara. Može se zaključiti da su komentari građana novinara o svim kandidatima bili pretežito negativni.

Tablica 18. Rezultati Shapiro-Wilkovog testa normalnosti raspodjele rezultata na T-portalu

	W	p-value	alpha	normal
SO(Ker)	0,70	0,000	0,05	no
SO(Bal)	0,82	0,000	0,05	no
SO (Bil)	0,83	0,000	0,05	no
SO (S)	0,71	0,000	0,05	no
a	0,88	0,004	0,05	no
i	0,89	0,004	0,05	no
rp	0,83	0,000	0,05	no

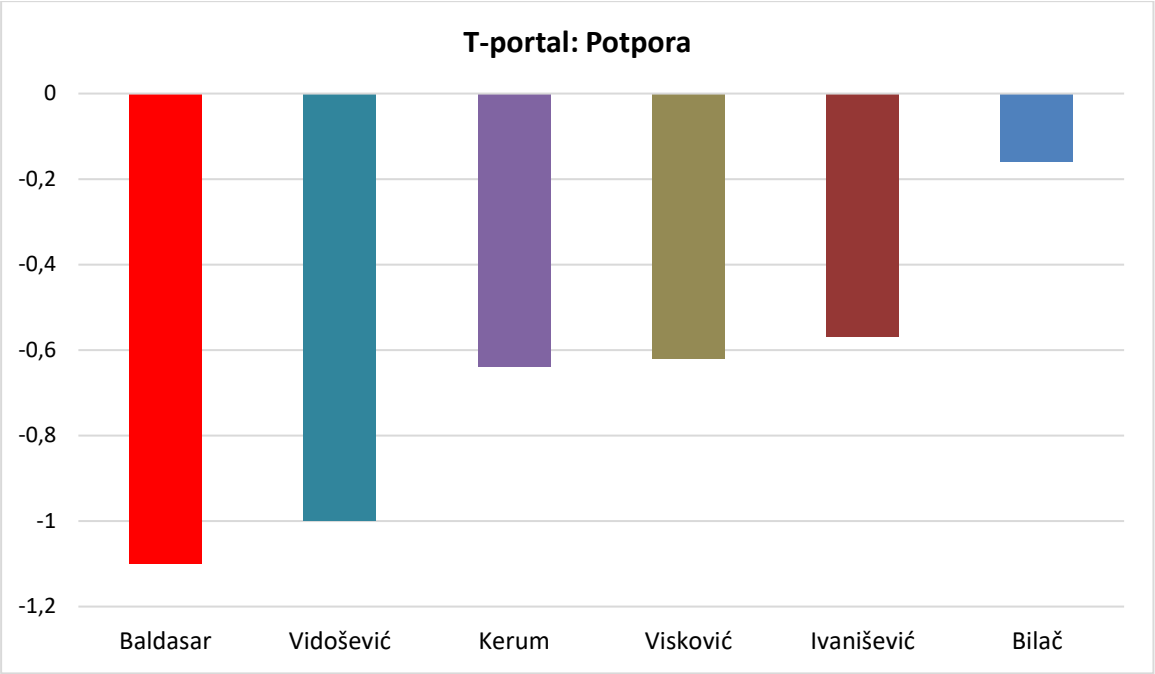
Tablica 18. prikazuje rezultate Shapiro-Wilkovog testa za SO komentara kandidata koje je na istraživanim portalima komentiralo barem 20 građana novinara te za razinu polemičnosti, interaktivnosti i argumentiranosti. Vidljivo je da za nijednu mjerenu varijabla raspodjela rezultata nije imala odlike normalne distribucije.

3.4.2. Odlike kandidata

Tablica 19. Prosječne vrijednosti SO u odnosu na odlike kandidata na T-portalu

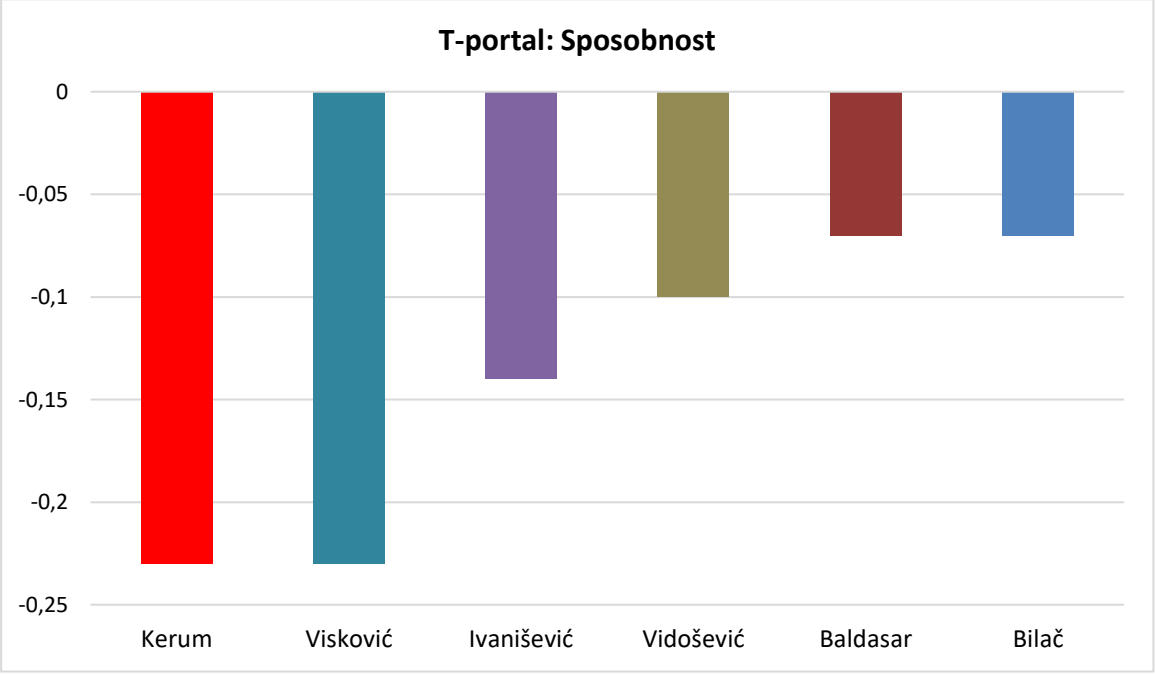
	PO	SP	PR	OD	MO	IZ	DO	KR
Kerum	-0,64	-0,23	-0,17	-0,15	-0,36	-0,04	0,00	-0,23
Visković	-0,62	-0,23	0,00	-0,08	-0,69	0,00	0,00	0,00
Vidošević	-1,00	-0,10	-0,05	0,00	-0,24	0,00	0,00	0,00
Baldasar	-1,10	-0,07	0,00	-0,05	-0,66	-0,02	-0,10	-0,05
Bilač	-0,16	-0,07	0,00	0,00	-0,47	0,02	0,00	-0,07
Ivanišević	-0,57	-0,14	0,00	-0,07	-0,43	0,00	0,00	-0,79

Tablica 19. prikazuje rezultate dobivene za srednje vrijednosti SO komentara u kategorijama: Potpora, Sposobnost, Pristojnost, Moralnost, Odgovornost, Izgled, Domoljublje i Kriminalnost. Željko Kerum imao je najniže srednje vrijednosti SO komentara u kategorijama Sposobnost (-0,23), Pristojnost (-0,17), Odgovornost (-0,15) i Izgled (-0,04). U kategoriji Domoljublje bio je ocijenjen jedino Ivo Baldasar (-0,1), a u kategoriji Potpora za njega je bila najniža srednja vrijednost SO komentara (-1,1). U kategoriji Izgled najviša srednja vrijednost SO komentara bila je pozitivna i odnosila se na Sanju Bilač (0,02). Moralnost je komentirana kod svih kandidata i za sve je kandidate srednja vrijednost SO komentara u ovoj kategoriji bila negativna, a najniža je bila za Anđelku Visković (-0,69) i Ivu Baldasara (-0,66). U kategoriji Kriminalnost najlošije je bio ocijenjen Vjekoslav Ivanišević (-0,79).



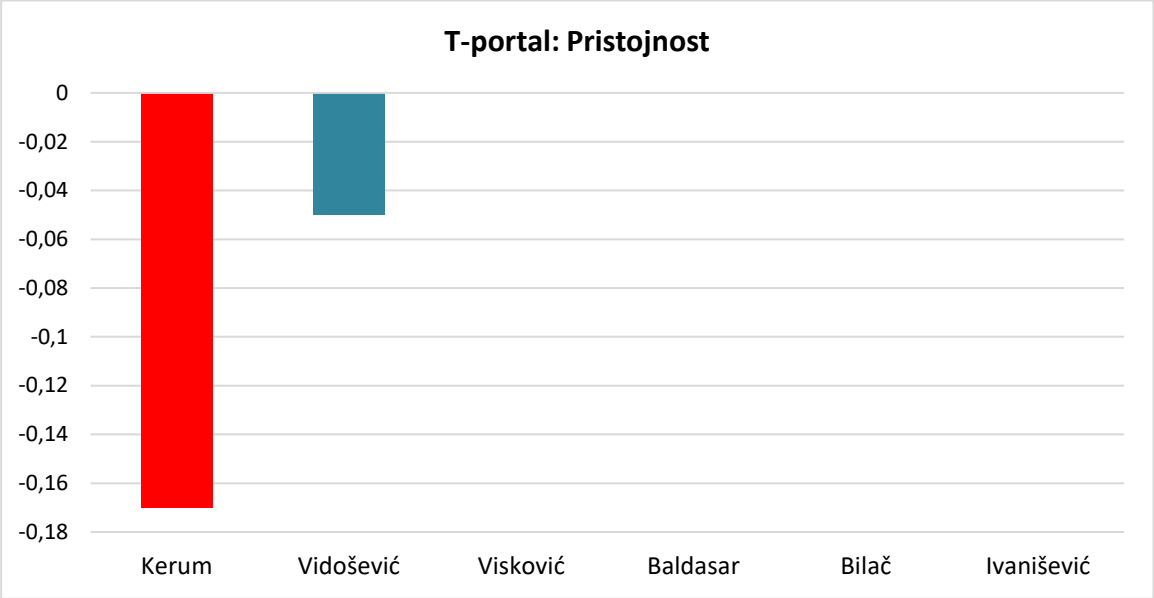
Graf 24. Prosječna SO komentara koji se odnose na pružanje potpore kandidatu na T-portalu

Graf 24. prikazuje prosječne SO komentara u kategoriji Potpora iz kojeg se uočava da je najmanje potpore dobio Ivo Baldasar, a najbolji je rezultat u toj kategoriji, premda i dalje negativan, imala Sanja Bilač.



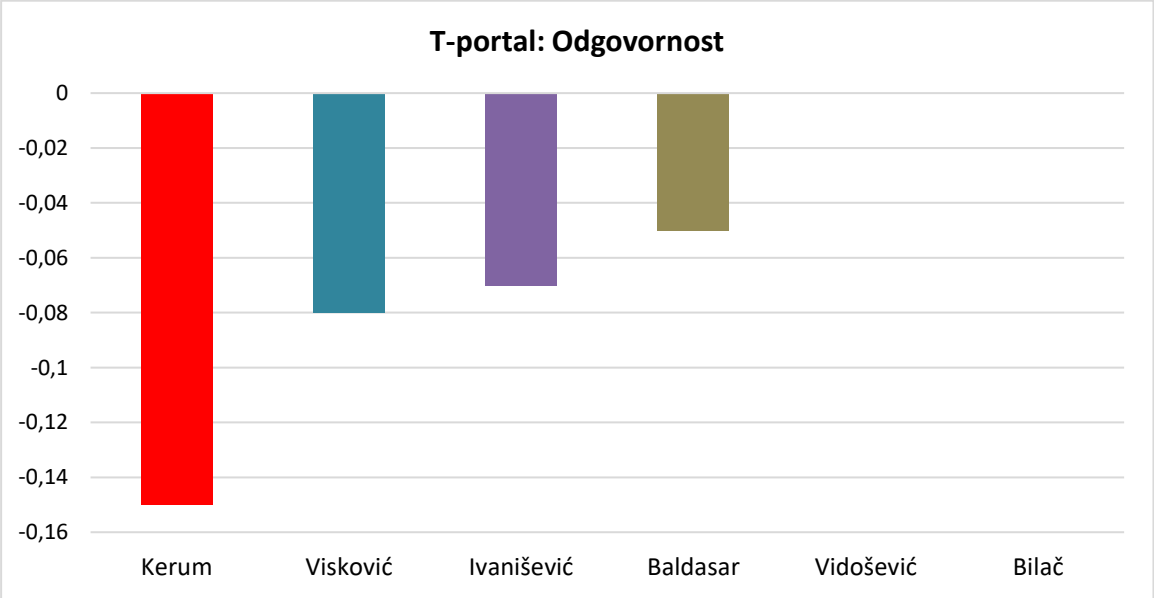
Graf 25. Prosječna SO komentara o sposobnosti kandidata na T-portalu

Grraf 25. prikazuje prosječne SO komentara u kategoriji Sposobnost iz kojeg se uočava da su najmanje sposobnima ocijenjeni Željko Kerum i Anđelka Visković, a najbolji su rezultat u ovoj kategoriji, premda i dalje negativan, imali Sanja Bilač i Ivo Baldasar.



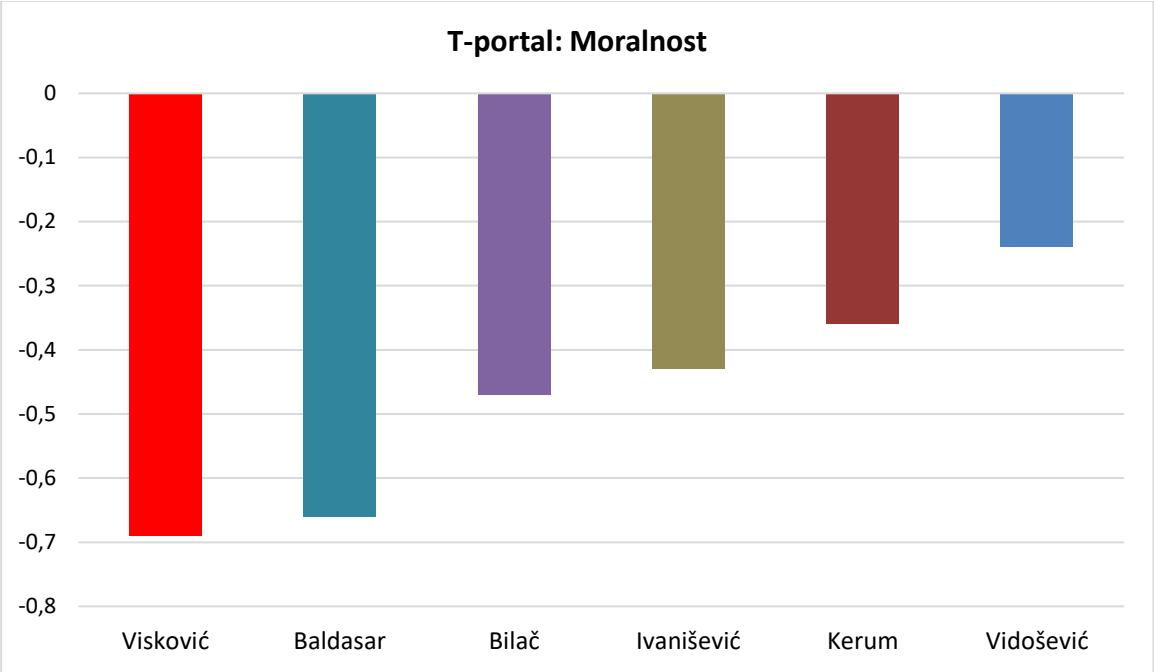
Graf 26. Prosječna SO komentara o pristojnosti kandidata na T-portalu

Graf 26. prikazuje prosječne SO komentara u kategoriji Pristojnost iz kojeg se uočava da je najmanje pristojnim ocijenjen Željko Kerum, a nakon njega Damir Vidošević. Preostali kandidati u ovoj kategoriji nisu bili komentirani ili je ukupna SO komentara o njima s obzirom na ovu odliku bila nula.



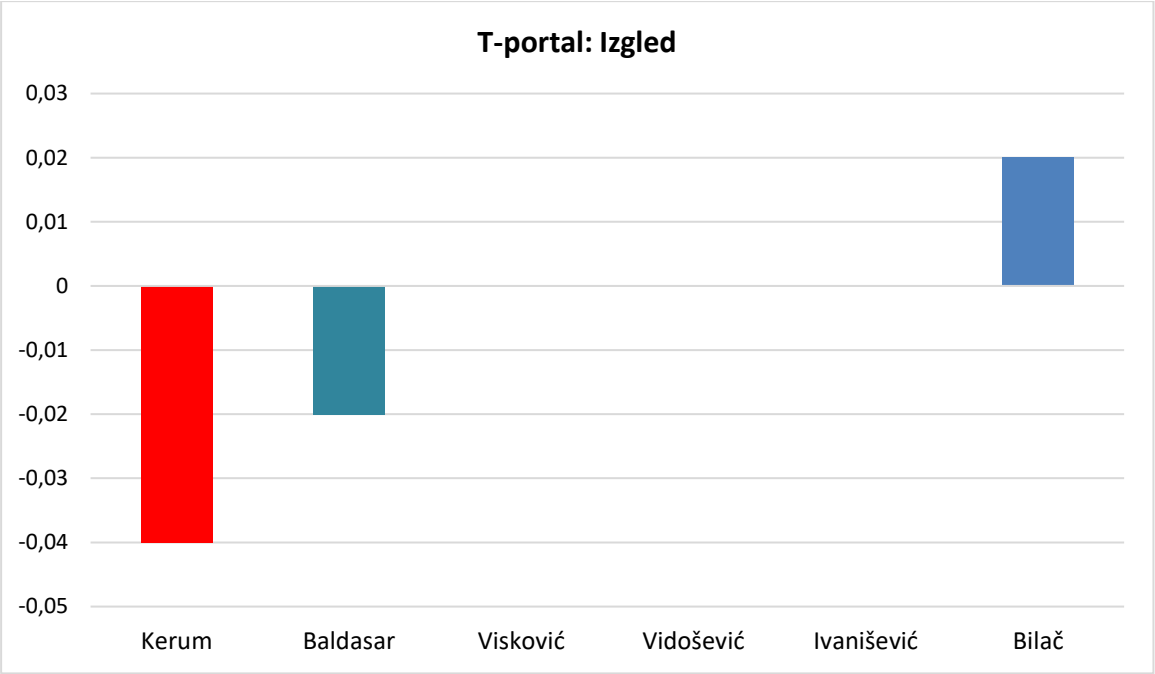
Graf 27. Prosječna SO komentara o odgovornosti kandidata na T-portalu

Graf 27. prikazuje prosječne SO komentara u kategoriji Odgovornost iz kojeg se uočava da je kao najmanje odgovoran ocijenjen Željko Kerum, zatim Anđelka Visković i Vjekoslav Ivanišević, a najbolji je rezultat u toj kategoriji, premda i dalje negativan, postigao Ivo Baldasar. Preostali kandidati u toj kategoriji nisu bili komentirani ili je ukupna SO komentara o njima s obzirom na ovu odliku bila nula.



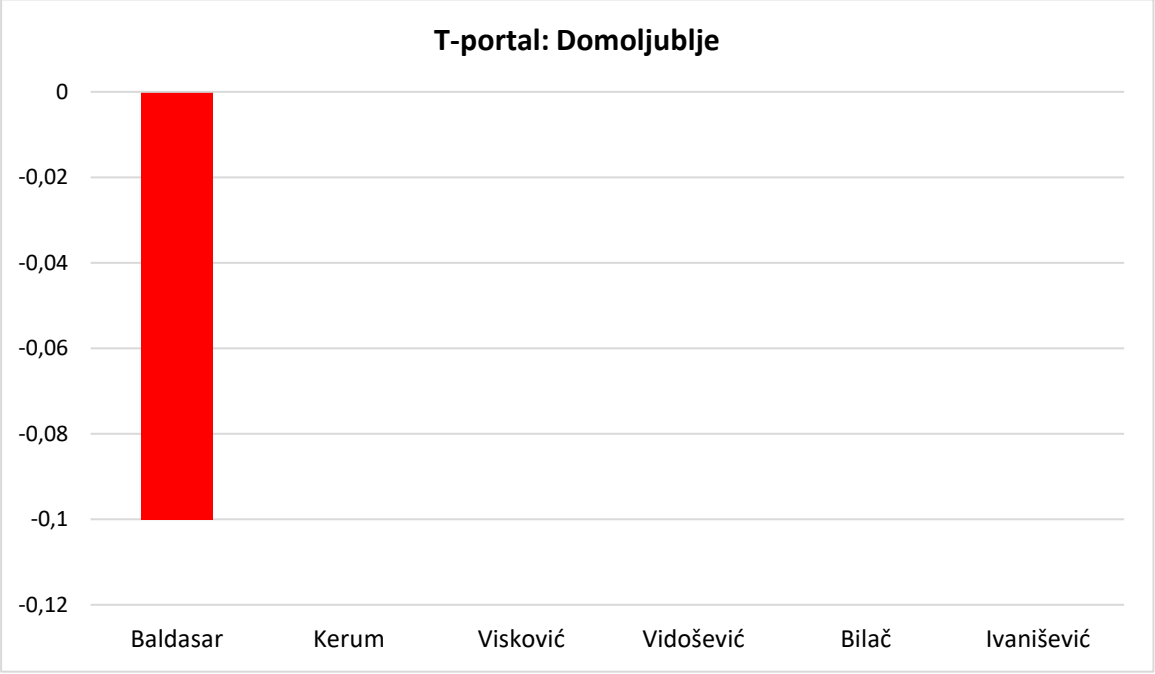
Graf 28. Prosječna SO komentara o moralnosti kandidata na T-portalu

Graf 28. prikazuje prosječne SO komentara u kategoriji Moralnost iz kojeg se uočava da je najmanje moralnom ocijenjena Anđelka Visković, a najbolji je rezultat u ovoj kategoriji, premda i dalje negativan, postigao Damir Vidošević.



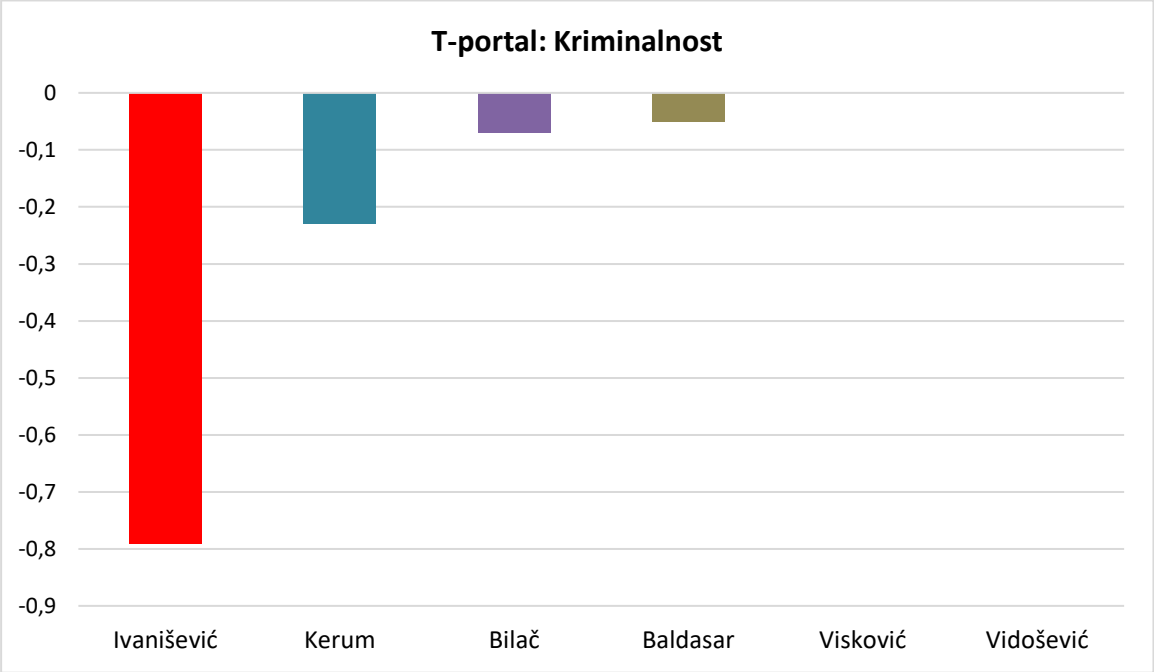
Graf 29. Prosječna SO komentara o izgledu kandidata na T-portalu

Graf 29. prikazuje prosječne SO komentara u kategoriji Izgled iz kojeg se uočava da je najslabije ocijenjen Željko Kerum, zatim Ivo Baldasar, a najbolji je rezultat u ovoj kategoriji postigla Sanja Bilač. Preostali kandidati u ovoj kategoriji nisu bili komentirani ili je ukupna SO komentara o njima s obzirom na ovu odliku bila nula.



Graf 30. Prosječna SO komentara o domoljublju kandidata na T-portalu

Graf 30. prikazuje prosječne SO komentara u kategoriji Domoljublje iz kojeg se uočava da je najslabije u ovoj kategoriji ocijenjen Ivo Baldasar. Preostali kandidati u ovoj kategoriji nisu bili komentirani ili je ukupna SO komentara o njima s obzirom na ovu odliku bila nula.



Graf 31. Prosječna SO komentara o kriminalnosti kandidata na T-portalu

Graf 31. prikazuje prosječne SO komentara u kategoriji Kriminalnost iz kojeg se uočava da je najslabije u toj kategoriji ocijenjen Vjekoslav Ivanišević, zatim Željko Kerum, Sanja Bilač i Ivo Baldasar. Preostali kandidati u toj kategoriji nisu bili komentirani ili je ukupna SO komentara s obzirom na ovu odliku bila nula.

Analizom SO komentara, u odnosu na različite odlike kandidata, može se utvrditi da prevladavaju negativni stavovi, da su se građani novinari najnegativnije izražavali o kandidataima u kategorijama Kriminalnost i Moralnost.

3.4.3. Odlike konverzacije

Tablica 20. Centralne vrijednosti razine polemičnosti, interaktivnosti i argumentiranosti na T-portalu

	a	i	rp
Med	6,98%	16,90%	2,023
Mod	0,00%	0,00%	1,083
Mean	7,33%	21,47%	2,014

Tablica 20. prikazuje rezultate dobivene za centralne vrijednosti razine polemičnosti, argumentiranosti i interaktivnosti komentara na članke. Medijan za interaktivnost iznosio je 16,90%, za argumentiranost 6,98%, a za razinu polemičnosti 2,014. Niska razina polemičnosti i argumentiranosti upućuje na zaključak da je na T-portalu komunikacija građana novinara imala odlike niske razine javne rasprave. Nešto veća interaktivnost može se povezati sa preprirkama ili pohvalama među pojedinim građanima novinarima, zbog čega u dubljim slojevima konverzacije nije sudjelovao veći broj građana novinara.

3.4.4. Teme, sentimenti i polemičnost konverzacije

Tablica 21. Popis novinskih članaka i postotak pozitivnih komentara o kandidatima na T-portalu

Tema	Pozitivni komentari
Kerum: Građani Splita ne žele spomenik Tuđmanu!	50,00%
Kerum: Kerumu ipak globa zbog nenošenja kacige	42,11%
Kerum: 'Pitao sam jel treba kaciga, rekli su mi da ne treba'	34,15%
Kerum: Šundov: Briga nas za ministricu, stavit ćemo križ na Marjan!	34,04%
Kerum: Splićanima priređuje neviđen spektakl	18,92%
Bilač: Kerum je dužan na sve strane, to je čisti kriminal!	18,18%
Kerum: na jet-skiju otvorio Zapadnu obalu, fotograf pao u more	17,02%
Kerum: Moramo staviti križ prije nego što dođu komunisti	13,64%
Kerum: Splićani po sat i pol čekali u redu za ječam s plodovima mora	13,16%
Vidošević: KANDIDAT ZA GRADONAČELNIKA SPLITA Don Ivanov kandidat voza Jaguara, a moto mu je - umri muški	13,04%

Tablica 21. prikazuje popis prvih deset novinskih članaka i postotak pozitivnih komentara o kandidatima. Članak koji je imao najveći udio pozitivnih komentara (50,00%) bio

je o Željku Kerum i podizanju spomenika Tuđmanu, a nakon njega slijedi također članak o Željku Kerumu i vožnji motora bez kacige (42,11%).

Tablica 22. Popis novinskih članaka i postotak negativnih komentara o kandidatima na T-portalu

Tema	Negativni komentari
Kerum: Vjerovnici progone Keruma i njegove tvrtke!	90,91%
Kerum: Kerum sestru kandidirao za županicu splitsko-dalmatinsku	88,46%
Vidošević: Don Ivanov kandidat voza Jaguara, a moto mu je - umri muški	86,96%
Kerum: Moramo staviti križ prije nego što dođu komunisti	81,82%
Kerum: Splićani po sat i pol čekali u redu za ječam s plodovima mora	78,95%
Kerum: Sestru kandidirao za županicu splitsko-dalmatinsku	78,26%
Kerum: Splićanima priređuje neviđen spektakl	70,27%
Kerum: na jet-skiju otvorio Zapadnu obalu, fotograf pao u more	70,21%
Bilač: Kerum je dužan na sve strane, to je čisti kriminal!	59,09%
Kerum: 'Pitao sam jel treba kaciga, rekli su mi da ne treba'	58,54%

Tablica 22. prikazuje popis prvih deset novinskih članaka i postotak negativnih komentara o kandidatima. Najveći udio negativnih komentara zabilježen je na članak o Željku Kerumu i stečaju njegovih firmi (90,91%) te o kandidaturi njegove sestre za županicu.

Tablica 23. Popis novinskih članaka i razina polemičnosti na T-portalu

Tema	r_p
Kerum: Šundov: Briga nas za ministricu, stavit ćemo križ na Marjan!	5,013
Bilač: Kerum je dužan na sve strane, to je čisti kriminal!	3,043
Kerum: Kerum sestru kandidirao za županicu splitsko-dalmatinsku	3,029
Kerum: Građani Splita ne žele spomenik Tuđmanu!	3,023
Kerum: Splićani po sat i pol čekali u redu za ječam s plodovima mora	3,019
Kerum: na jet-skiju otvorio Zapadnu obalu, fotograf pao u more	3,018
Kerum: sestru kandidirao za županicu splitsko-dalmatinsku	3,012
Bilač: Splitu treba status metropole	2,143
Baldasar: 'Ni križ ni Tuđman nisu prioritet Splita'	2,100
Kerum: Kerumova zapadna obala puna robe iz uvoza, za koš za smeće - 3000 kuna	2,100

Tablica 23. prikazuje popis prvih deset novinskih članaka i razinu polemičnosti konverzacije o njima. Najveću razinu polemičnosti postigao je članak o podizanju križa na Marjanu (5,013).

3.5. Portal Slobodna Dalmacija

Obrađeno je ukupno 4465 komentara napisanih na 216 novinskih članaka o kandidatima za splitskog gradonačelnika. Od toga se 3732 komentara odnosilo na kandidate, a 1093 na građane novinare.

3.5.1. Analiza sentimenata

Tablica 24. SO komentara na novinskom portalu Slobodna Dalmacija

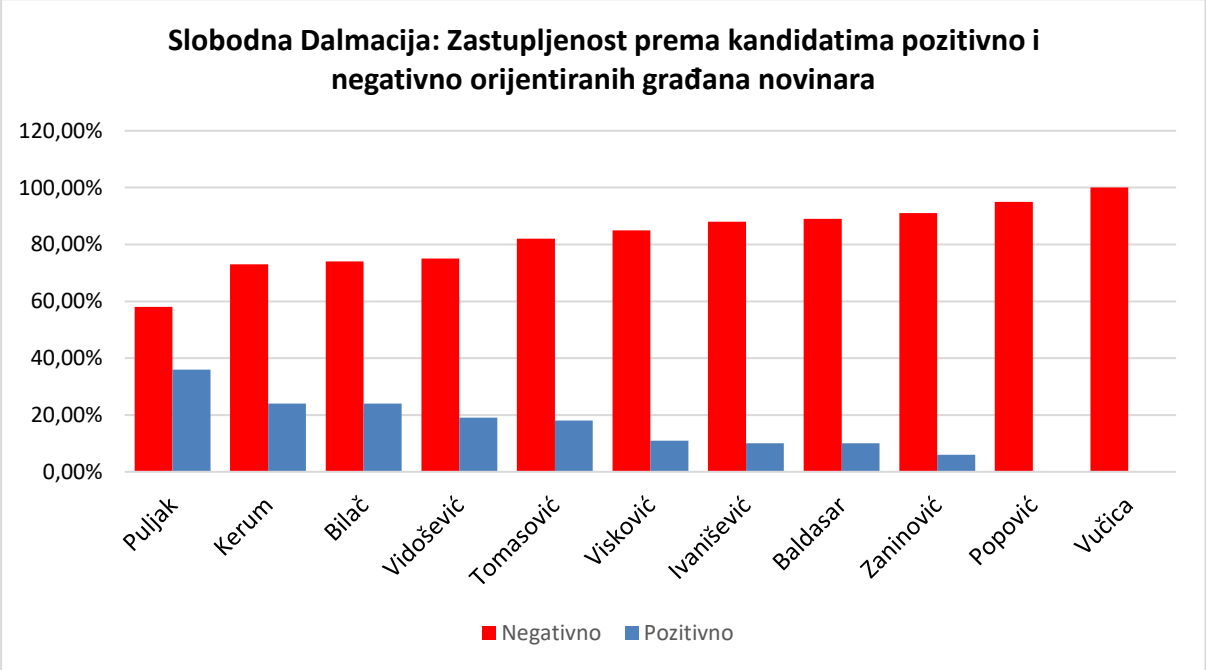
	Br. čl	Br. Kom.	Br. gr. n.	Avg SO	Med SO	Mod SO	Max	Min	Poz	Neg	Neu
Kerum	104	2729	568	-10,36	-2	-1	139	-432	24%	73%	3%
Baldasar	8	392	158	-6,30	-2	-1	7	-212	10%	89%	1%
Visković	10	310	120	-5,12	-2	-1	56	-198	11%	85%	4%
Ivanišević	16	640	218	-8,54	-1	-1	14	-260	10%	88%	2%
Bilač	8	159	97	-2,38	-1	-1	22	-34	24%	74%	2%
Vidošević	3	56	36	-1,58	-1	-1	16	-14	19%	75%	6%
Puljak	6	135	70	2,89	-1	-1	217	-23	36%	58%	6%
Tomasović	5	96	65	-1,09	-2	-1	34	-19	18%	82%	0%
Popović	2	25	19	-2,74	-2	-1	0	-6	0%	95%	5%
Vučica	1	32	25	-3,08	-2	-1	-1	-10	0%	100%	0%
Zaninović	7	134	79	-4,91	-3	-1	4	-44	6%	91%	3%
Građani n.		1098	219	-10	-4	-1	11	-193	9%	81%	10%

Tablica 24. prikazuje rezultate dobivene za centralne vrijednosti SO za svakog kandidata komentiranog na novinskom portalu Slobodne Dalmacije, broj napisanih članaka o kandidatu, broj komentara o kandidatu i broj građana novinara koji su komentirali kandidata. Uočava se da je najviše građana novinara s pozitivnim komentarima imala kandidatkinja Marijana Puljak (36%), a najmanje kandidati Marijo Popović (0 %) i Pero Vučica (0%). Najviše građana novinara negativno se izjašnjavalo o Peri Vučici (100%) i Mariju Popoviću (95%), pa se može zaključiti da su oni na dnu ljestvice kojom se mjeri naklonost građana novinara pojedinim kandidatima. Na isti način za Marijanu Puljak moglo bi se ustvrditi da je na vrhu te ljestvice, budući da je uz najveći udio građana novinara koji su se o njoj pozitivno izjašnjavali imala najmanji udio građana novinara koji su se o njoj negativno izjašnjavali (58%), a srednja vrijednost SO komentara o njoj je najviša (2,89). Na portalu Slobodne Dalmacije, nakon Marijane Puljak, najviše građana novinara s pozitivnim komentarima imali su Željko Kerum (24%) i Sanja Bilač (24%). Zanimljivo je uočiti da su kandidati velikih stranaka HDZ i SDP imali slične rezultate i nalaze se pri dnu ljestvice kojom se mjeri naklonost građana novinara

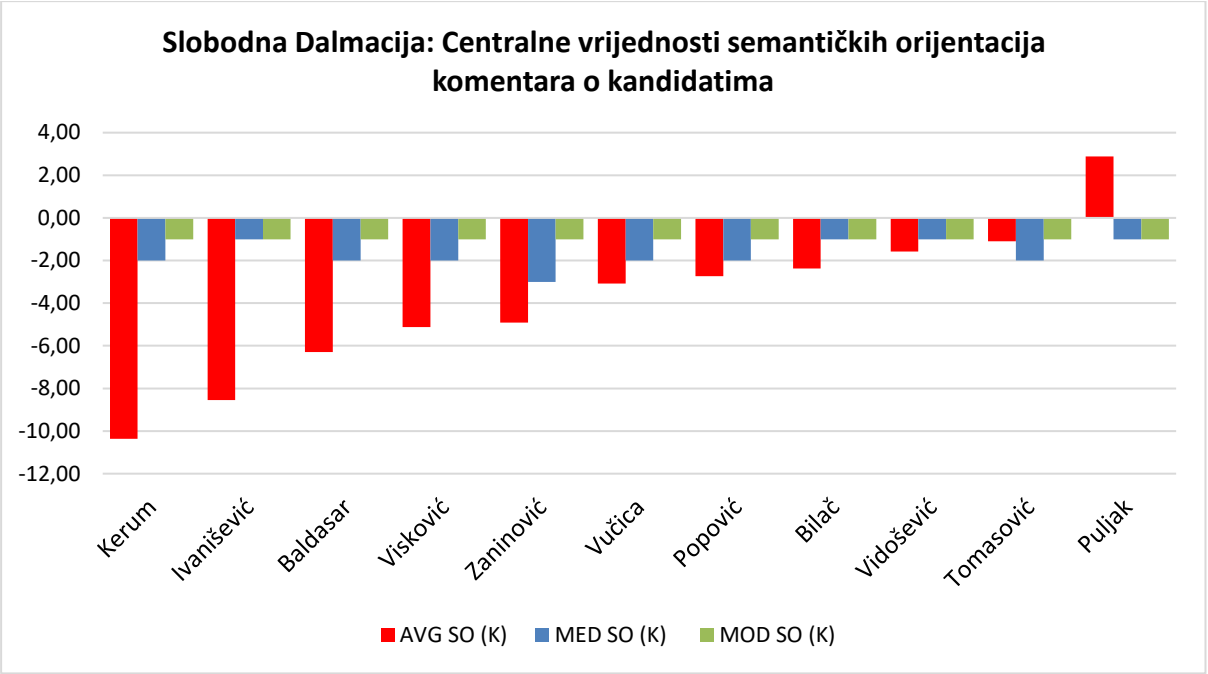
pojedinom kandidatu. Tako se o Vjekoslavu Ivaniševiću i Ivi Baldasaru pozitivno izjasnilo 10 % građana novinara, dok se o Ivaniševiću negativno izjasnilo 88%, a o Baldasaru 89% građana novinara.

Srednje vrijednosti SO komentara osjetljive su na izrazito negativne ili pozitivne SO komentara pojedinih građana novinara, što se na ovom portalu uočava kod većine kandidata, a najizraženije kod Željka Keruma za kojeg je srednja vrijednost ukupne SO komentara iznosila -10.36, a medijan -2. No, velika razlika između medijana i srednje vrijednosti uočava se i kod Vjekoslava Ivaniševića, Ive Baldasara i Anđelke Visković. Iz toga se može zaključiti da su pojedini građani novinari imali izrazito negativne komentare o spomenutim kandidatima. Tako je ukupna SO komentara građana novinara koji je imao najviše negativnih komentara o Željku Kerumu iznosila – 432, a ukupna SO komentara građanina novinara koji je o njemu imao najviše pozitvnih komentara iznosila je 139.

SO komentara koji su se odnosili na građane novinare bile su pretežito negativne. 81 % građana novinara imalo je negativne komentare o drugim građanima novinarima, 9% pozitivne, a 10 % neutralne. Centralne vrijednosti ukupnih SO komentara o građanima novinarima bile su negativne. Srednja vrijednost iznosila je – 10, medijan -4, a mod -1. Velika razlika između medijana i srednje vrijednosti i ovdje upućuje na zaključak da su pojedini građani novinari imali izrazito negativne komentare o drugim građanima novinarima.



Graf 32. Udio građana novinara koji su se negativno i pozitivno izjasnili o kandidatima na portalu Slobodna Dalmacija



Graf 33. Centralne vrijednosti SO komentara o kandidatima na portalu Slobodna Dalmacija

Graf 32. grafički prikazuje udio građana novinara koji su se pozitivno i negativno izjasnili o kandidatima na novinskom portalu Slobodne Dalmacije, a graf 33. centralne vrijednosti ukupnih SO komentara. Može se zaključiti da su stavovi građana novinara o svim kandidatima bili pretežito negativni.

Tablica 25. Rezultati Shapiro-Wilkovog testa normalnosti raspodjele rezultata na portalu Slobodna Dalmacija

	W	p-value	alpha	normal
SO(Ker)	0,36	0,000	0,05	no
SO(Bil)	0,76	0,000	0,05	no
SO (Bal)	0,32	0,000	0,05	no
SO (S)	0,45	0,000	0,05	no
a	0,86	0,000	0,05	no
i	0,91	0,000	0,05	no
r_p	0,66	0,000	0,05	no

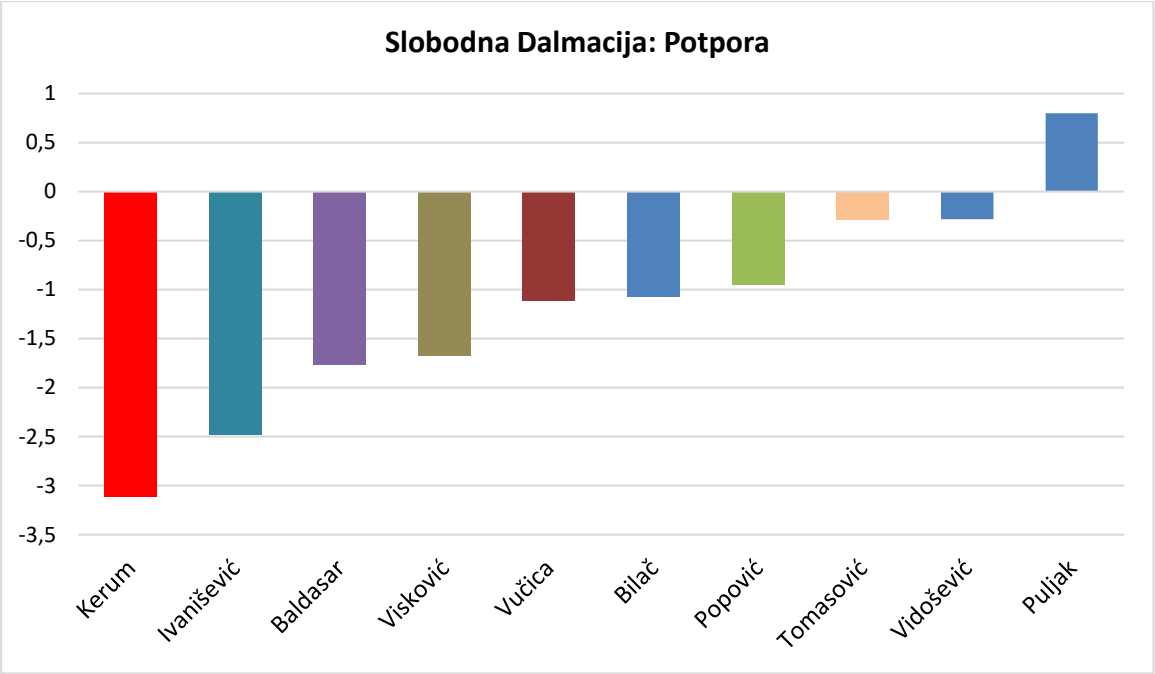
Tablica 25. prikazuje rezultate Shapiro-Wilkovoga testa za varijable ukupne SO komentara o građanima novinarima i kandidatima za koje je bilo barem 20 mjerenja te razine argumentiranosti, polemičnosti i interaktivnosti. Vidljivo je da raspodjele rezultata nisu imale odlike normalne distribucije.

3.5.2. Odlike kandidata

Tablica 26. Prosječne vrijednosti SO u odnosu na odlike kandidata na portalu Slobodna Dalmacija

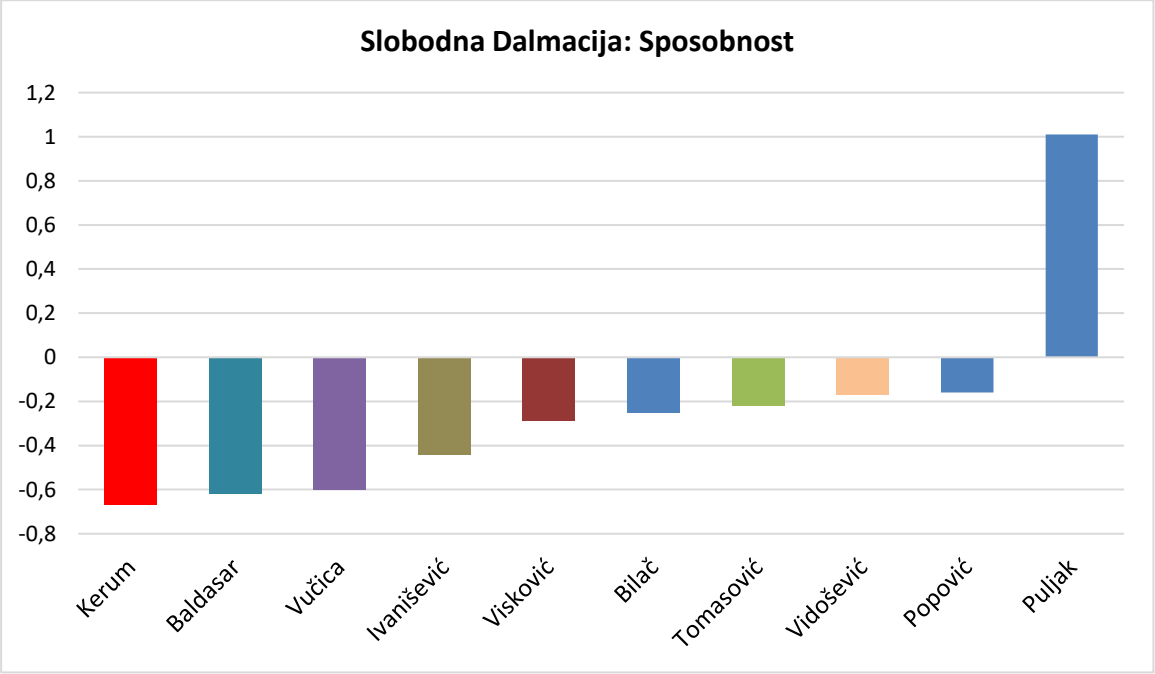
	Po	Sp	Pr	Od	Mor	Iz	Do	Kr
Puljak	*0,80*	*1,01*	*0,37*	*0,10*	*0,60*	*-0,01*	*0,01*	*0,00*
Vučica	*-1,12*	*-0,60*	*-0,04*	*-0,12*	*-1,20*	*0,00*	*0,00*	*0,00*
Popović	*-0,95*	*-0,16*	*-0,05*	*-0,21*	*-1,32*	*0,00*	*-0,05*	*0,00*
Vidošević	*-0,28*	*-0,17*	*0,00*	*-0,17*	*-0,89*	*0,00*	*-0,08*	*0,00*
Tomasović	*-0,29*	*-0,22*	*-0,03*	*-0,03*	*-0,54*	*0,00*	*0,03*	*-0,02*
Visković	*-1,68*	*-0,29*	*-0,09*	*-0,32*	*-2,58*	*0,02*	*-0,03*	*-0,16*
Baldasar	*-1,77*	*-0,62*	*0,00*	*-0,68*	*-2,28*	*-0,08*	*-0,66*	*-0,20*
Bilač	*-1,07*	*-0,25*	*-0,01*	*-0,15*	*-0,79*	*0,09*	*0,01*	*-0,21*
Kerum	*-3,11*	*-0,67*	*-0,97*	*-0,89*	*-3,53*	*-0,09*	*-0,18*	*-0,91*
Ivanišević	*-2,48*	*-0,44*	*-0,17*	*-1,14*	*-2,70*	*-0,06*	*-0,18*	*-1,37*

Tablica 26. prikazuje rezultate dobivene za srednje vrijednosti SO komentara u kategorijama: Potpora, Sposobnost, Pristojnost, Moralnost, Odgovornost, Izgled, Domoljublje i Kriminalnost. Željko Kerum imao je najniže srednje vrijednosti SO komentara u kategorijama Potpora (-3,1), Sposobnost (-0,67), Pristojnost (-0,97), Moralnost (-3,53) i Izgled (-0,09). Marijana Puljak imala je najviše i uglavnom pozitivne srednje vrijednosti SO komentara u gotovo svim kategorijama. Najvišu srednju vrijednost SO komentara dobila je u kategoriji Sposobnost (1,01), zatim u kategorijama Potpora (0,80), Moralnost (0,60), Pristojnost (0,37) i Odgovornost (0,10). U kategoriji Kriminalnost nije bila ocijenjena, a jedinu negativnu srednju vrijednost SO komentara postigla je u kategoriji Izgled (-0,01). U kategoriji Izgled najpozitivnije je bila ocijenjena Sanja Bilač (0,09). U kategoriji Domoljublje najvišu srednju vrijednost SO komentara dobio je Hrvoje Tomasović (0,03), a najnižu Ivo Baldasar (-0,66). U kategoriji Kriminalnost najnižu srednju vrijednost semantičke orijentacije komentara imao je Vjekoslav Ivanišević (-1,37).



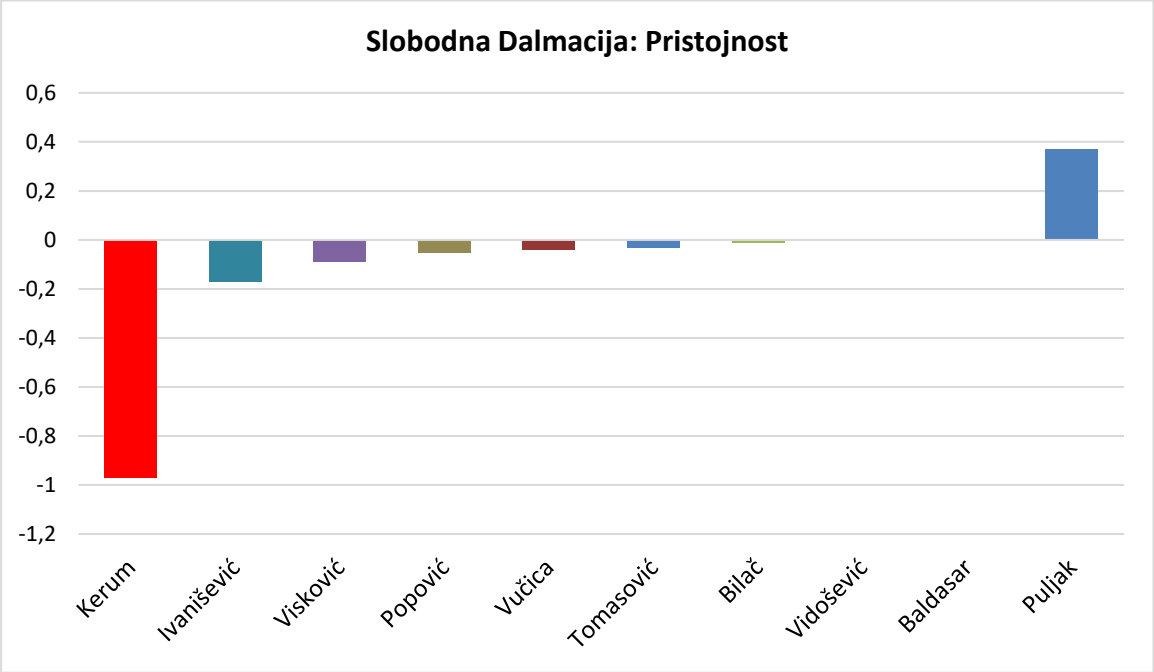
Graf 34. Prosječna SO komentara koji se odnose na pružanje potpore kandidatu na portalu Slobodna Dalmacija

Graf 34. prikazuje prosječne SO komentara u kategoriji Potpora iz kojeg se uočava da je najviše potpore dobila Marijana Puljak, a najmanje Željko Kerum.



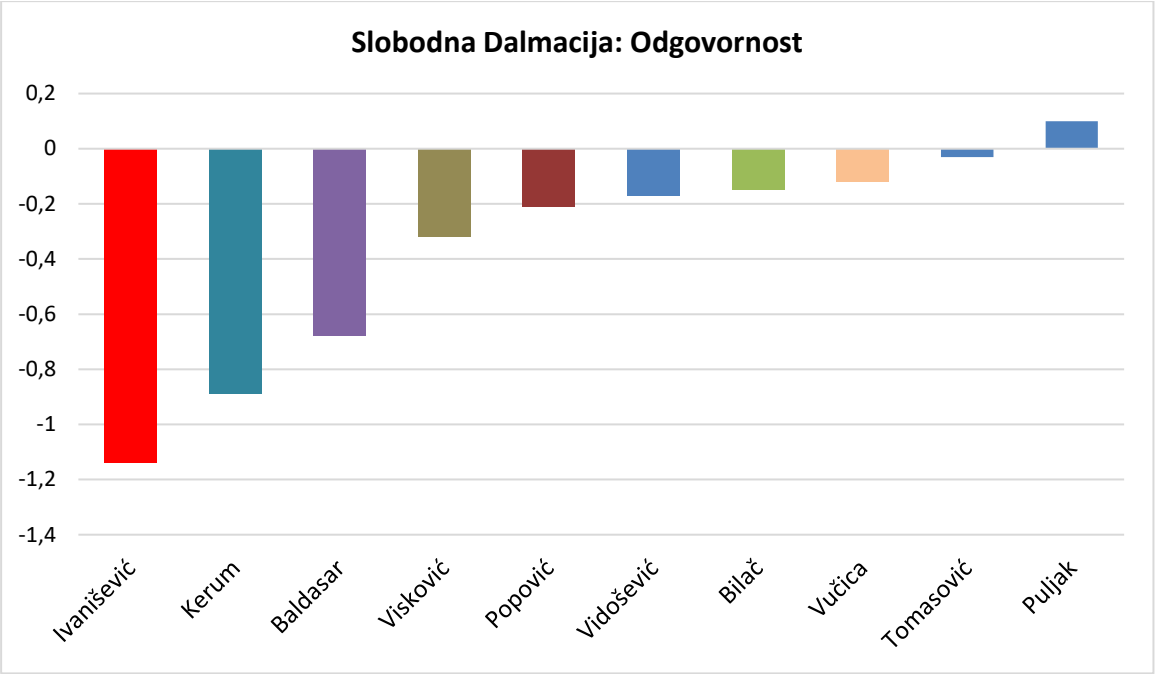
Graf 35. Prosječna SO komentara o sposobnosti kandidata na portalu Slobodna Dalmacija

Graf 35. prikazuje prosječne SO komentara u kategoriji Sposobnost iz kojeg se uočava da je najviše pozitivnih komentara o sposobnosti dobila Marijana Puljak, a najmanje Željko Kerum. Svi su kandidati, osim Puljak, negativno ocijenjeni.



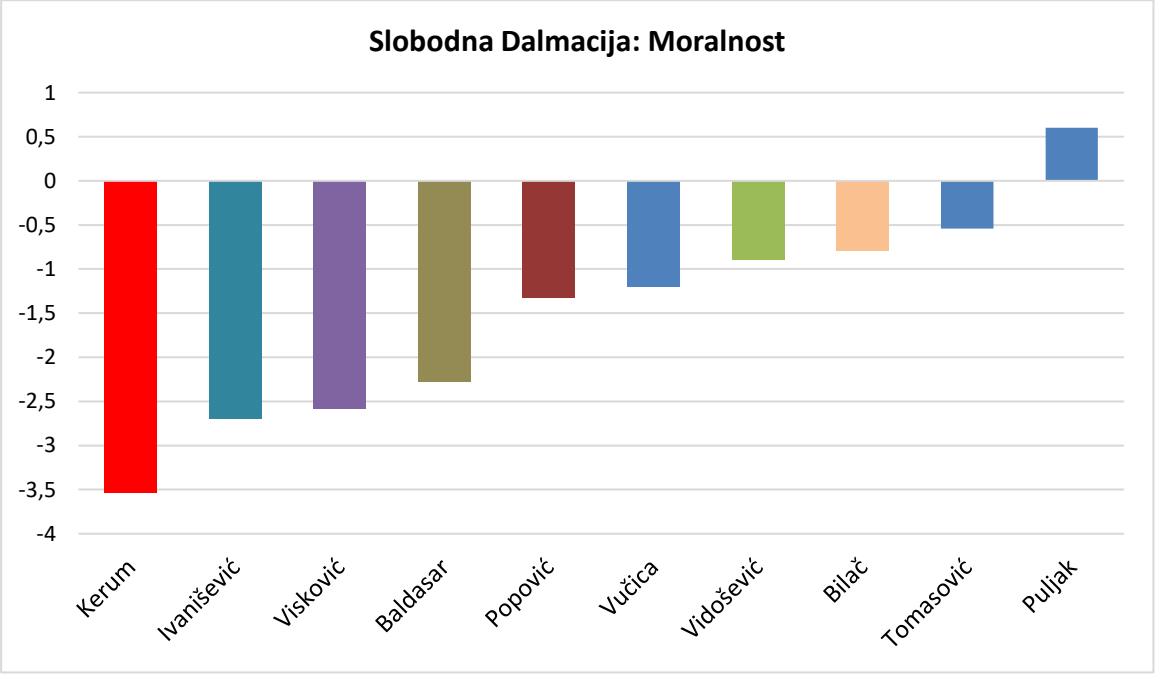
Graf 36. Prosječna SO komentara o pristojnosti kandidata na portalu Slobodna Dalmacija

Graf 36. prikazuje prosječne SO komentara u kategoriji Pristojnost iz kojeg se uočava da je najviše pozitivnih komentara o pristojnosti dobila Marijana Puljak, a najmanje Željko Kerum koji je najnegativnije ocijenjen. Negativnu su ocijenu dobili i Vjekoslav Ivanišević, Anđelka Visković, Mario Popović, Pero Vučica i Hrvoje Tomasović. Preostali kandidati u toj kategoriji nisu bili komentirani ili je ukupna SO komentara o njima s obzirom na ovu odliku bila nula.



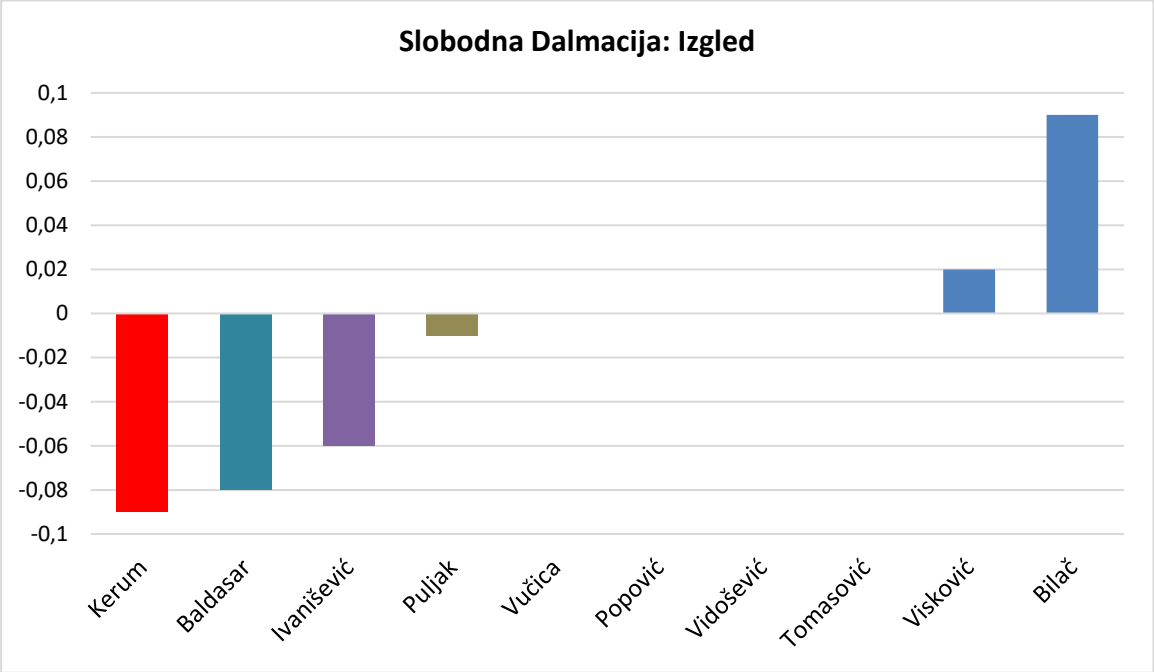
Graf 37. Prosječna SO komentara o odgovornosti kandidata na portalu Slobodna Dalmacija

Graf 37. prikazuje prosječne SO komentara u kategoriji Odgovornost iz kojeg se uočava da je najviše pozitivnih komentara o odgovornosti dobila Marijana Puljak, a najmanje Vjekoslav Ivanišević.



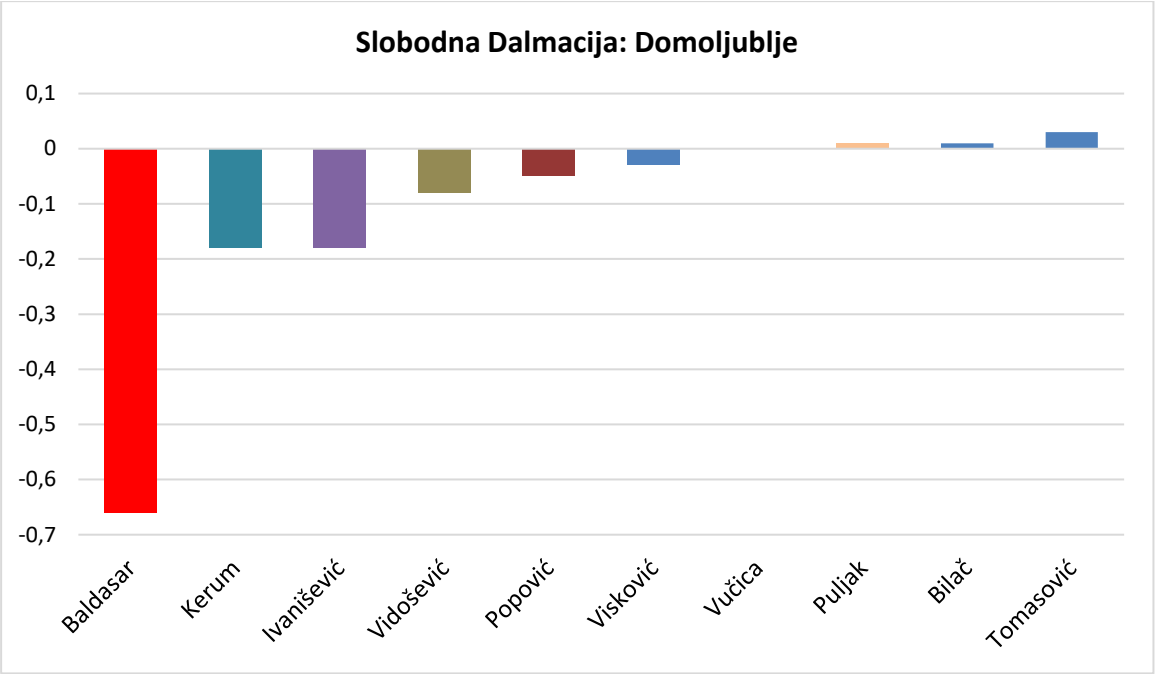
Graf 38. Prosječna SO komentara o moralnosti kandidata na portalu Slobodna Dalmacija

Graf 38. prikazuje prosječne SO komentara u kategoriji Moralnost iz kojeg se uočava da je najviše pozitivnih komentara o moralnosti dobila Marijana Puljak, a najmanje Željko Kerum.



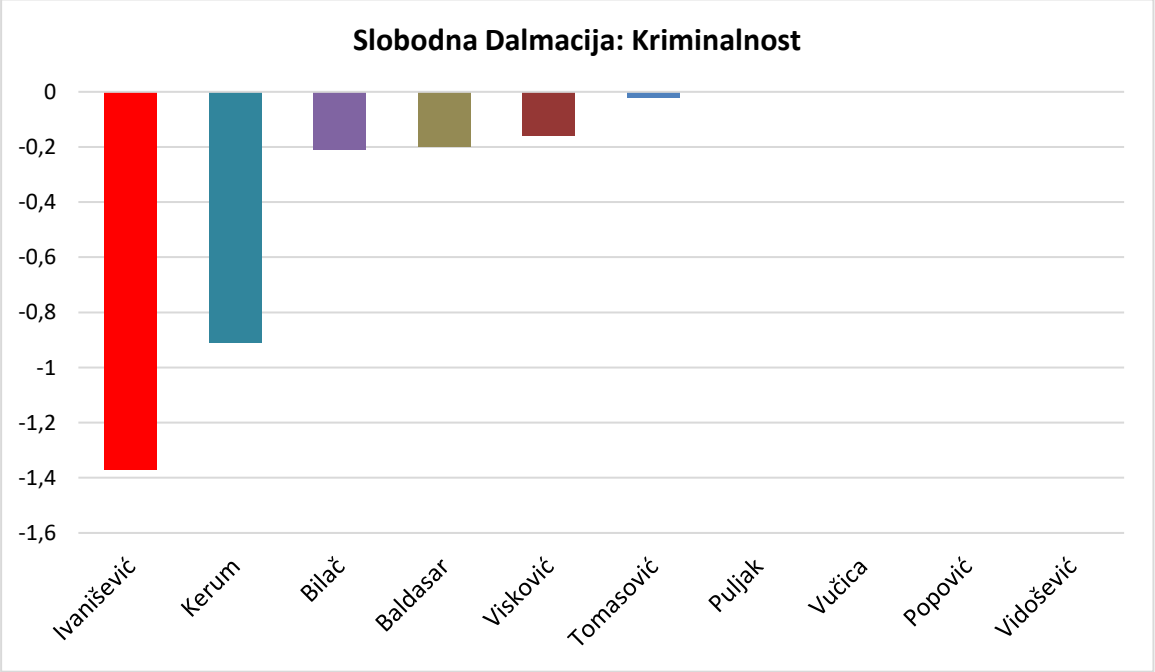
Graf 39. Prosječna SO komentara o izgledu kandidata na portalu Slobodna Dalmacija

Graf 39. prikazuje prosječne SO komentara u kategoriji Izgled iz kojeg se uočava da je najviše pozitivnih komentara o izgledu dobila Sanja Bilač, a nakon nje Anđelka Visković. Najlošije je ocijenjen Željko Kerum. Negativno su ocijenjeni Ivo Baldasar, Vjekoslav Ivanišević i Marijana Puljak. Preostali kandidati u toj kategoriji nisu bili komentirani ili je ukupna SO komentara s obzirom na ovu odliku bila nula.



Graf 40. Prosječna SO komentara o domoljublju kandidata na portalu Slobodna Dalmacija

Graf 40. prikazuje prosječne SO komentara u kategoriji Domoljublje iz kojeg se uočava da je najviše pozitivnih komentara o domoljublju dobio Hrvoje Tomasović, a najlošiji je rezultat imao Ivo Baldasar. Pozitivno su ocijenjeni Marijana Puljak i Sanja Bilač. Preostali su kandidati bili negativno ocijenjeni, a Pero Vučica u toj kategoriji nije bio komentiran.



Graf 41. Prosječna SO komentara o kriminalnosti kandidata na portalu Slobodna Dalmacija

Graf 41. prikazuje prosječne SO komentara u kategoriji Kriminalnost iz kojeg se uočava da je najviše negativnih komentara o kriminalnosti dobio Vjekoslav Ivanišević, zatim Željko Kerum, Sanja Bilač, Ivo Baldasar, Anđelka Visković i Hrvoje Tomasović. Preostali kandidati u toj kategoriji nisu bili komentirani ili je ukupna SO komentara o njima s obzirom na ovu odliku bila nula.

Analizom SO komentara, u odnosu na različite odlike kandidata, može se utvrditi da prevladavaju negativni stavovi, da su se građani novinari najviše negativno izražavali o kandidatima u kategorijama Kriminalnost i Moralnost.

3.5.3. Odlike konverzacije

Tablica 27. Centralne vrijednosti razine polemičnosti, interaktivnosti i argumentiranosti na portalu Slobodna Dalmacija

	a	i	r_p
Med	12,50%	20,00%	2,029
Mod	0,00%	0,00%	1,143
Mean	15,40%	21,05%	1,949

Tablica 27. prikazuje rezultate dobivene za centralne vrijednosti razine polemičnosti, argumentiranosti i interaktivnosti komentara na članke, gdje je broj mjerenja jednak broju objavljenih članaka. Medijan za interaktivnost iznosio je 20 %, za argumentiranost 12,50%, a za razinu polemičnosti 2,029. Niska razina polemičnosti i argumentiranosti upućuje na zaključak da je na portalu Slobodna Dalmacija komunikacija građana novinara imala odlike niske razine javne rasprave. Nešto veća interaktivnost može se povezati sa prepirkama ili pohvalama među pojedinim građanima novinarima, zbog čega u dubljim slojevima konverzacije nije sudjelovao veći broj građana novinara.

3.5.4. Teme, sentimenti i polemičnost konverzacije

Tablica 28. Popis novinskih članaka i postotak pozitivnih komentara o kandidatima na novinskom portalu Slobodna Dalmacija

Tema	Pozitivni komentari
Puljak: Kriza nije vrijeme za megalomanske projekte	47,83%
Bilač: Kod nje nema uhljeba	47,06%
Kerum: Zapadna obala digla cijenu hotelu Marjan	44,68%
Baldasar: Žrnovnica može postat bolje mjesto	44,44%
Kerum: Najava otvaranja zapadne obale	42,11%
Puljak Pokrenula akciju 'sendvič za kasnije' u Splitu	42,10%
Kerum: Križ na Marjanu	41,41%
Kerum: Počela gradnja križa na Marjanu	39,13%
Kerum: Igra križić kružić u Saboru	38,71%
Visković: Slikala se u četvercu s čelnicima nezavisnih lista: Idući tjedan ovo može biti osmerac!	36,84%

Tablica 28. prikazuje popis prvih deset novinskih članaka prema postotku pozitivnih komentara o kandidatima. Članak koji je imao najveći udio pozitivnih komentara (47,83%) bio je o Marijani Puljak, nakon njega o Sanji Bilač (47,06%) te o Kerumu i Zapadnoj obali (44,68%).

Tablica 29. Popis novinskih članaka i postotak negativnih komentara o kandidatima na novinskom portalu Slobodna Dalmacija

Tema	Negativni komentari
Zaninović: HDZ me molio da ne napadam Ivaniševića	100,00%
Bilač: Napustila HDZ	100,00%
Ivanišević: Spomenik zaslužuju Tuđman i Smoje	96,97%
Kerum: Dao sam sebi u najam kafiće na Zapadnoj	96,00%
Ivanišević: Moj bespravni zid je samo papirnati grijeh	95,00%
Zaninović: Očistit ću Split od lopovluka i politike	94,87%
Kerum: Donirao pustinjakinje	94,12%
Kerum: Najavio kandidaturu	93,33%
Kerum: Crkva nije protiv križa	93,33%
Kerum: Neću lagat i neću se minjat, a moja vizija je preporod Splita	92,86%

Tablica 29. prikazuje popis prvih deset novinskih članaka prema postotku negativnih komentara. Stopostotni udio negativnih komentara imali su članci o Sanji Bilač koja je napustila

HDZ i o Tomislavu Zaninoviću koji je komentirao HDZ, nakon čega slijedi članak o Vjekoslavu Ivaniševiću i njegovom komentaru podizanja križa na Marjanu (96,97%).

Tablica 30. Popis novinskih članaka i razina polemičnosti na novinskom portalu Slobodna Dalmacija

Tema	R_p
Kerum: Natječaj za kip Tuđmana	6,008
Zajedničko: Da su sutra izbori u Splitu, u drugi krug ušli bi Grubišić i Ivanišević	5,014
Kerum: I danas sam najveći posjednik u Splitu	5,013
Kerum: Ministrica zabranjuje 10m križa	5,011
Kerum: Križ na Marjanu	5,007
Kerum: Potpisi protiv spomenika i križa	5,005
Kerum: Stižu križ i Tuđman	4,020
Kerum: Zapadna obala digla cijenu hotelu Marjan	4,019
Kerum: Najveće postignuće - napravio dva sina	4,010
Kerum: Dopremljen spomenik Tuđmanu	4,007

Tablica 30. prikazuje popis deset novinskih članaka s najvećom razinom polemičnosti konverzacija građana novinara. Najveću razinu postigao je članak o podizanju Tuđmanova spomenika (6,008), a više razine polemičnosti zabilježene su kod svih članaka o podizanju križa i spomenika Tuđmanu.

3.6. Portal Dalmacija News

Obrađeno je ukupno 1963 komentara napisanih na 210 novinskih članaka o kandidatima za splitskog gradonačelnika. Od toga se 1803 komentara odnosilo na kandidate, a 283 na građane novinare.

3.6.1. Analiza sentimenata

Tablica 31. Rezultati za novinski portal Dalmacija News

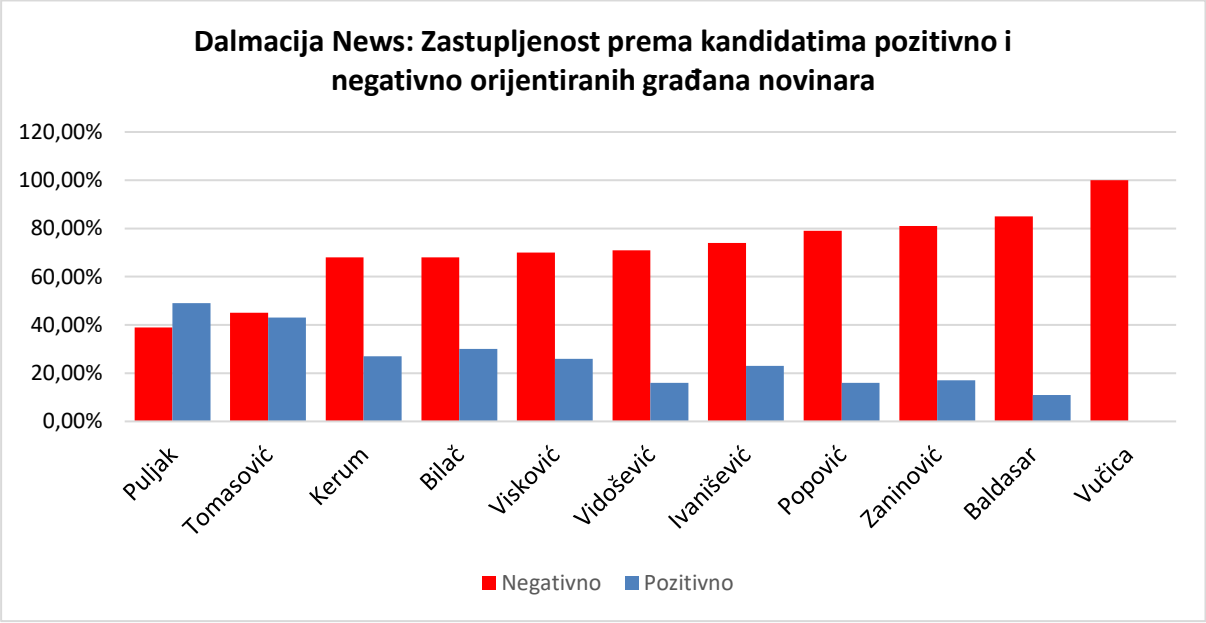
	Br. čl	Br. kom.	Br. gr. n.	Avg SO	Med SO	Mod SO	Max	Min	Poz	Neg	Neu
Kerum	68	867	398	-2,88	-1	-1	43	-272	27%	68%	5%
Baldasar	29	331	183	-3,42	-2	-1	9	-125	11%	85%	4%
Visković	22	265	115	-1,39	-1	-1	48	-76	26%	70%	4%
Ivanišević	43	356	183	-2,77	-1	-1	15	-176	23%	74%	3%
Bilač	11	62	44	-1,05	-1	-1	4	-7	30%	68%	2%
Vidošević	4	40	31	-1,39	-1	-1	4	-16	16%	71%	13%
Puljak	12	60	41	-0,22	0	1	6	-11	49%	39%	12%
Tomasović	8	87	58	-0,09	0	1	25	-11	43%	45%	12%
Popović	5	84	62	-1,95	-1,5	-1	7	-25	16%	79%	5%
Vučica	1	10	6	-3	-3	-4	-1	-6	0%	100%	0%
Zaninović	12	102	63	-2,7	-2	-1	5	-18	17%	81%	2%
Građani n.		286	150	-2,93	-2	-1	7	-22	9%	71%	20%

Tablica 31. prikazuje rezultate dobivene za centralne vrijednosti SO za svakog kandidata komentiranog na novinskom portalu Dalmacija News, broj napisanih članaka o kandidatu, broj komentara o kandidatu i broj građana novinara koji su komentirali kandidata. Uočava se da je najviše građana novinara s pozitivnim komentarima imala kandidatkinja Marijana Puljak (49%) i kandidat Hrvoje Tomasović (43%), a najmanje kandidati Pero Vučica (0 %) i Ivo Baldasar (11%). Najviše građana novinara negativno se izjašnjavalo o Peri Vučici (100%) i Ivi Baldasaru (85%), pa se može zaključiti da su oni na dnu ljestvice kojom se mjeri naklonost građana novinara pojedinim kandidatima. Na isti način za Marijanu Puljak moglo bi se ustvrditi da je na vrhu te ljestvice, budući da je uz najveći udio građana novinara koji su se o njoj pozitivno izjašnjavali imala i najmanji udio građana novinara koji su se o njoj negativno izjašnjavali (39%). Uz Marijanu Puljak na vrhu ljestvice je i Hrvoje Tomasović koji je imao visok udio građana novinara koji su se o njemu pozitivno izjašnjavali i manji udio građana novinara koji su se o njemu negativno izjašnjavali (45%). Najvišu vrijednost srednje vrijednosti SO komentara imao je kandidat Hrvoje Tomasović (-0,09), a nakon njega Marijana Puljak (-

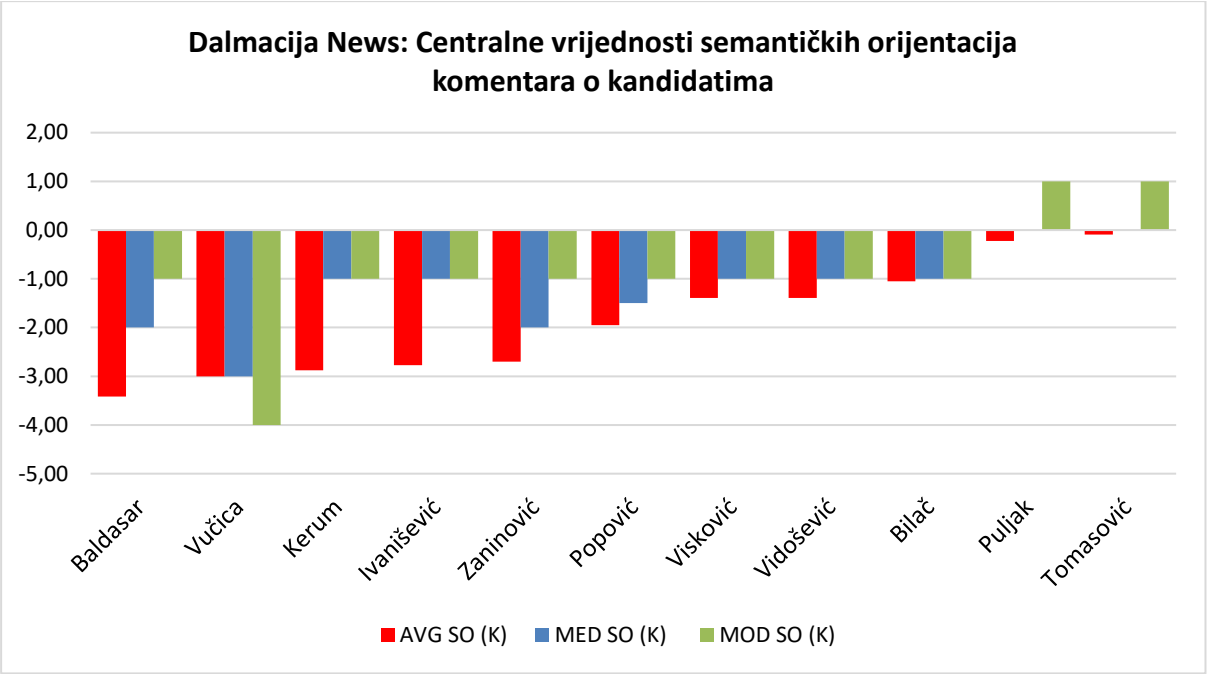
0,22). Na portalu Dalmacija News uočava se razlika u naklonosti građana novinara prema kandidatima velikih stranaka. S obzirom na udio građana novinara koji su se o kandidatima pozitivno i negativno izjasnili uočava se da je kandidat SDP-a na portalu Dalmacija News imao manju potporu od kandidata HDZ-a. Tako se o Vjekoslavu Ivaniševiću pozitivno izjasnilo 23 % građana novinara, a negativno 74% građana novinara, što je bolji rezultat od onog koji je postigao Ivo Baldasar.

Srednje vrijednosti SO komentara osjetljive su na izrazito negativne ili pozitivne SO komentara pojedinih građana novinara, što se na ovom portalu uočava kod kandidata Željka Keruma za kojeg je srednja vrijednost ukupne SO komentara građana novinara iznosila -2,38, a medijan -1, zatim kod Ive Baldasara za kojeg je srednja vrijednost SO komentara iznosila -3,42, a medijan -2 te kod Vjekoslava Ivaniševića za kojeg je srednja vrijednost SO komentara iznosila -2,77, a medijan -1. Iz toga se može zaključiti da su pojedini građani novinari imali izrazitije negativne komentare o spomenutim kandidatima. Tako je ukupna SO komentara građana novinara koji je imao najnegativnije komentare o Željku Kerumu iznosila – 272, a ukupna SO komentara građana novinara koji je o njemu imao najpozitivnije komentare 43.

SO komentara koji su se odnosili na građane novinare bile su pretežito negativne. 71 % građana novinara imalo je negativne komentare o drugim građanima novinarima, 9% pozitivne, a 20 % neutralne. Centralne vrijednosti ukupnih SO komentara o građanima novinarima bile su negativne. Srednja vrijednost iznosila je – 2,93, medijan -2, a mod -1.



Graf 42. Udio građana novinara koji su se negativno i pozitivno izjasnili o kandidatima na portalu Dalmacija News



Graf 43. Centralne vrijednosti SO komentara o kandidatima na portalu Dalmacija News

Graf 42. prikazuje udio građana novinara koji su se pozitivno i negativno izjasnili o kandidatima na novinskom portalu Dalmacija News, a graf 43. centralne vrijednosti ukupnih SO komentara. Može se zaključiti da su stavovi građana novinara o svim kandidatima, osim za Marijanu Puljak i Hrvoja Tomasovića, bili pretežito negativni.

Tablica 32. Rezultati Shapiro-Wilkovog testa normalnosti raspodjele rezultata na portalu Dalmacija News

	W	p-value	alpha	normal
SO(Ker)	0,25	0,000	0,05	no
SO(Bil)	0,92	0,005	0,05	no
SO (Bal)	0,31	0,000	0,05	no
SO (S)	0,71	0,000	0,05	no
a	0,62	0,000	0,05	no
i	0,88	0,000	0,05	no
r_p	0,90	0,000	0,05	no

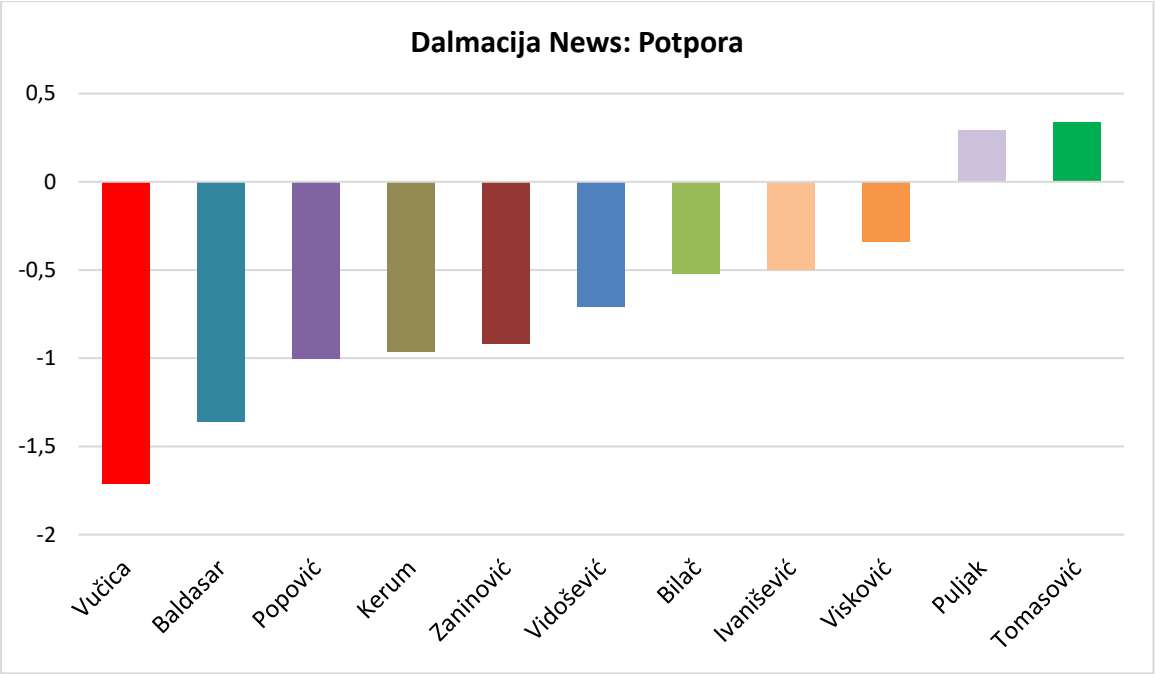
Tablica 32. prikazuje rezultate Shapiro-Wilkovoga testa za raspodjelu rezultata SO komentara za koje je bilo barem 20 mjerenja, razine argumentiranosti, polemičnosti i interaktivnosti. Vidljivo je da nijedna raspodjela nije imala odlike normalne distribucije.

3.6.2. Odlike kandidata

Tablica 33. Prosječne vrijednosti SO u odnosu na odlike kandidata na portalu Dalmacija News

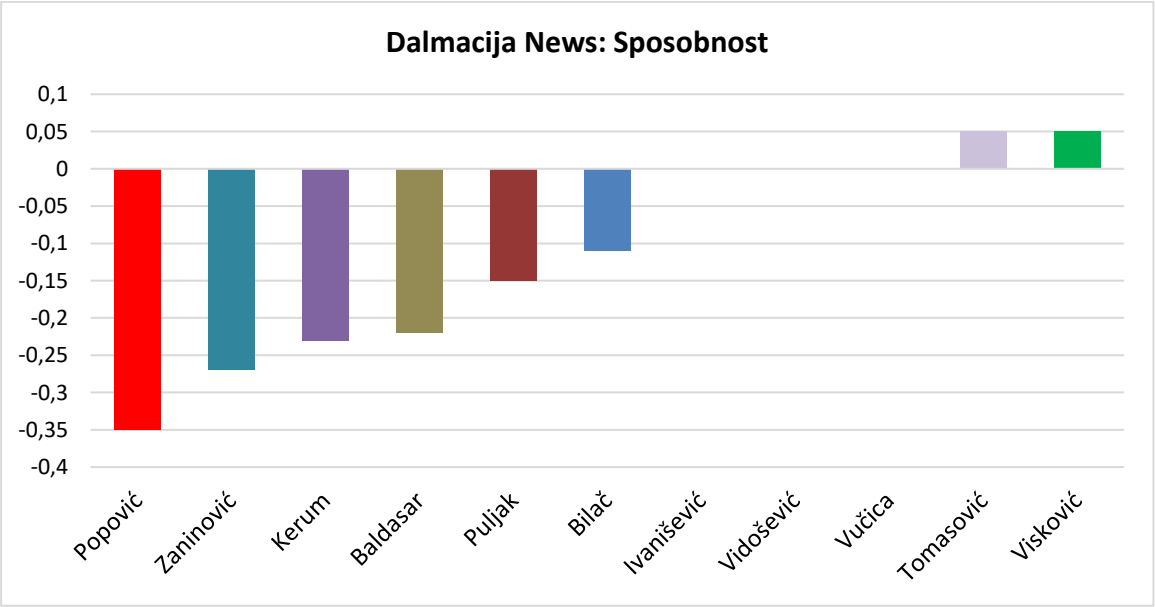
	Po	*Sp*	*Pr*	*Od*	*Mor*	*Iz*	*Do*	*Kr*
Baldasar	-1,36	-0,22	0,00	-0,27	-1,03	-0,03	-0,36	-0,15
Bilač	-0,52	-0,11	0,00	-0,05	-0,39	0,02	0,02	-0,02
Ivanišević	-0,50	0,00	-0,11	0,01	-0,41	-1,13	-0,06	-0,57
Kerum	-0,96	-0,23	-0,22	-0,03	-0,86	-0,23	-0,02	-0,03
Popović	-1,00	-0,35	-0,18	-0,10	-0,31	-0,03	0,03	-0,02
Puljak	0,29	-0,15	0,00	0,00	-0,34	0,00	0,00	-0,02
Tomasović	0,34	0,05	-0,03	0,00	-0,36	0,00	-0,05	-0,03
Vidošević	-0,71	0,00	0,00	-0,06	-0,42	0,00	-0,13	-0,06
Visković	-0,34	0,05	-0,02	0,04	-1,04	-0,02	0,00	-0,07
Vučica	-1,71	0,00	-0,14	0,00	-0,14	-1,43	0,00	-0,14
Zaninović	-0,92	-0,27	0,00	-0,19	-0,81	-0,03	0,02	-0,49

Tablica 33. prikazuje rezultate dobivene za srednje vrijednosti SO komentara u kategorijama: Potpora, Sposobnost, Pristojnost, Moralnost, Odgovornost, Izgled, Domoljublje i Kriminalnost. Pero Vučica imao je najniže srednje vrijednosti SO komentara u kategorijama Potpora (-1,71) i Moralnost (-1,43). Međutim, ovaj je kandidat imao malen ukupan broj komentara (10) zbog čega ovi rezultati nemaju dovoljnu statističku težinu. Nakon njega u kategoriji Potpora najnižu srednju vrijednost SO komentara imao je Ivo Baldasar (-1, 36). Ivo Baldasar najnižu srednju vrijednost SO komentara imao je i u kategorijama Odgovornost (-0,27) i Domoljublje (-0,36). Marijo Popović imao je najnižu srednju vrijednost SO komentara u kategoriji Sposobnost (-0,35). Ako se zbog malog broja ukupnih komentara izuzme kandidat Pero Vučica, tada je u kategoriji Izgled najlošije bio ocijenjen Vjekoslav Ivanišević (-1,13). Ivanišević je najlošije bio ocijenjen i u kategoriji Kriminalnost (-0,57). Najviše ocjene u kategoriji Potpora dobili su Hrvoje Tomasović (0,34) i Marijana Puljak (0,29), u kategoriji Sposobnost Anđelka Visković (0,05) i Hrvoje Tomasović (0,05), a u kategoriji Pristojnost Anđelka Visković (-0,02). U kategoriji Odgovornost najbolje je bila ocijenjena Anđelka Visković (0,04), a u kategoriji Moralnost Marijo Popović (-0,31), s tim da su slične rezultate u ovoj kategoriji postigli i Marijana Puljak (-0,34), Hrvoje Tomasović (-0,36), Sanja Bilač (-0,39) i Damir Vidošević (-0,42). U kategoriji Izgled najpozitivnije je bila ocijenjena Sanja Bilač (0,02). U kategoriji Domoljublje najbolje je bio ocijenjen Marijo Popović (0,03) te nakon njega Sanja Bilač (0,02) i Tomislav Zaninović (0,02). Najviše su rezultate u kategoriji Kriminalnost dobili kandidati Popović (-0,02), Bilač (-0,02) i Puljak (-0,02).



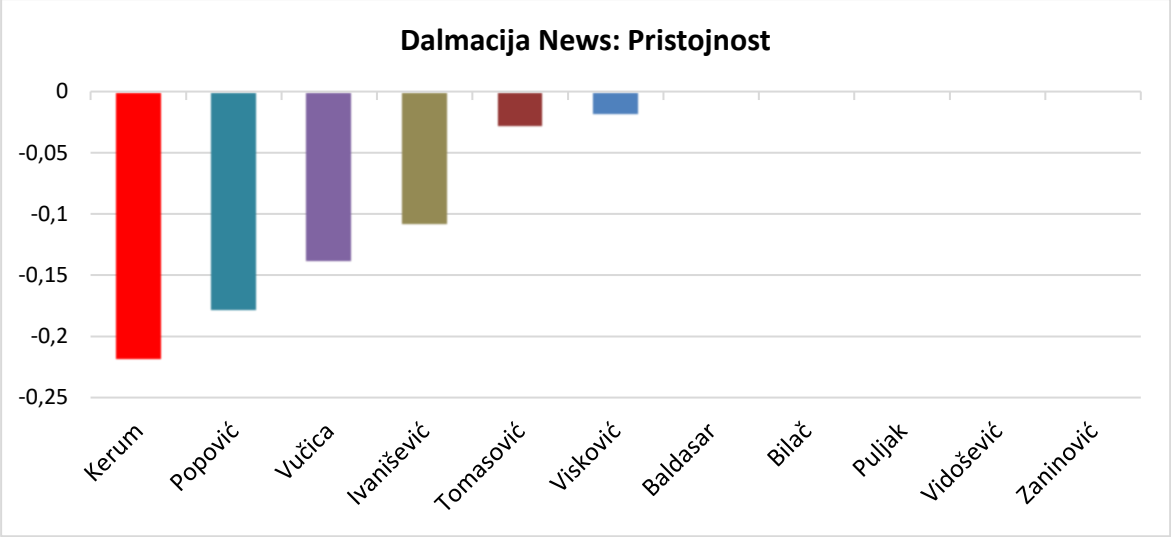
Graf 44. Prosječna SO komentara koji se odnose na pružanje potpore kandidatu na portalu Dalmacija News

Graf 44. prikazuje prosječne SO komentara u kategoriji Potpora iz kojeg se uočava da je najviše potpore dobio Hrvoje Tomasović, a najmanje Pero Vučica. Međutim, budući da Peru Vučicu nije komentirao dovoljno velik broj građana novinara rezultat ne možemo smatrati statistički važnim, pa je pouzdanije zaključiti da je najmanje potpore dobio Ivo Baldasar. Uz Tomasovića i Marijana Puljak je imala pozitivnu prosječnu SO komentara u ovoj kategoriji.



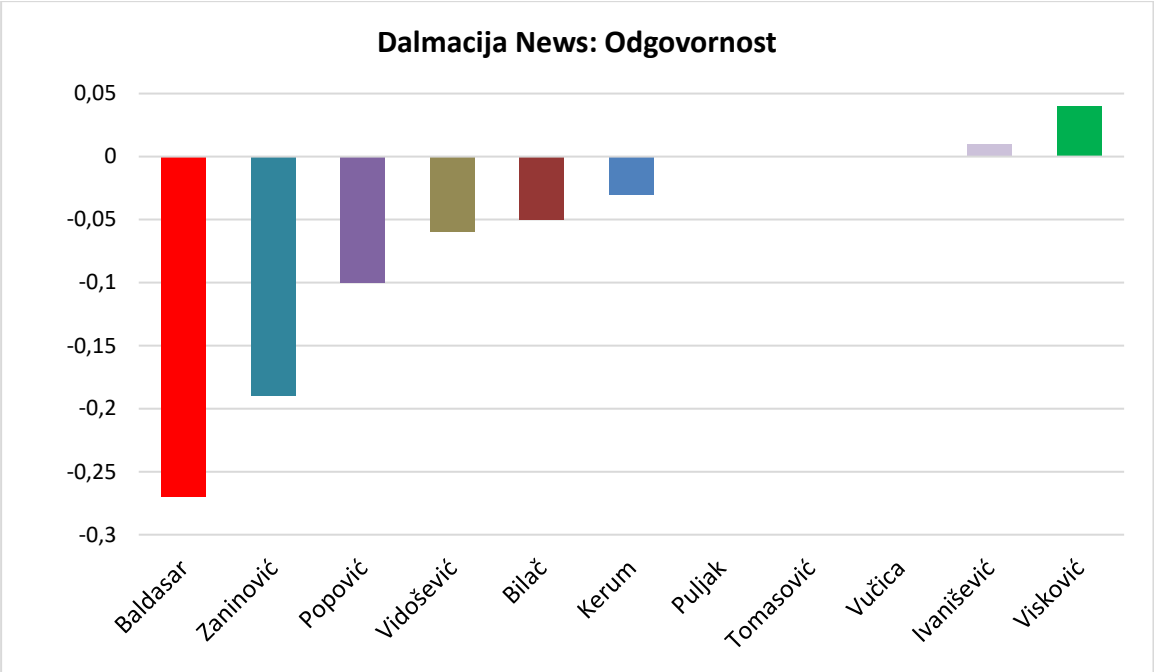
Graf 45. Prosječna SO komentara o sposobnosti kandidata na portalu Dalmacija News

Graf 45. prikazuje prosječne SO komentara u kategoriji Sposobnost iz kojeg se uočava da su najsposobnijima ocijenjeni Anđelka Visković i Hrvoje Tomasović, koji su imali pozitivne prosječne SO komentara u ovoj kategoriji, a negativno i najmanje sposobnim je ocijenjen Marijo Popović, zatim Tomislav Zaninović, Željko Kerum, Ivo Baldasar, Marijana Puljak i Sanja Bilač. Preostali kandidati u ovoj kategoriji nisu bili komentirani ili je ukupna SO komentara s obzirom na ovu odliku bila nula.



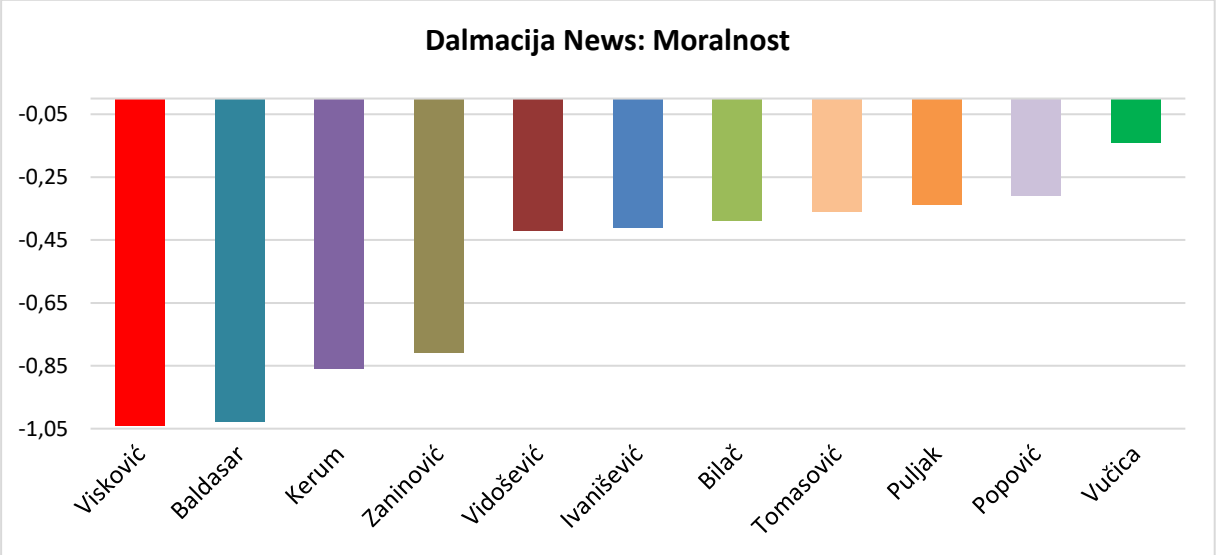
Graf 46. Prosječna SO komentara o pristojnosti kandidata na portalu Dalmacija News

Graf 46. prikazuje prosječne SO komentara u kategoriji Pristojnost iz kojeg se uočava da je najmanje pristojnim ocijenjen Željko Kerum, zatim Marijo Popović, Pero Vučica, Vjekoslav Ivanišević, Hrvoje Tomasović, Anđelka Visković i Ivo Baldasar. Nijedan kandidat nije imao pozitivnu SO komentara u ovoj kategoriji. Preostali kandidati u ovoj kategoriji nisu bili komentirani ili je ukupna SO komentara s obzirom na ovu odliku bila nula.



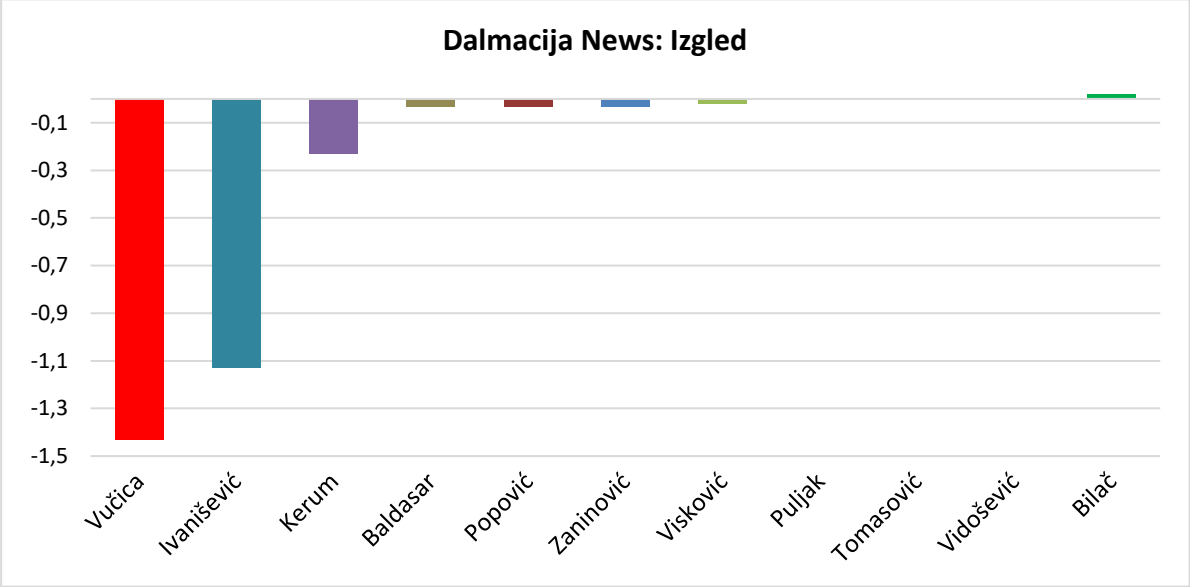
Graf 47. Prosječna SO komentara o odgovornosti kandidata na portalu Dalmacija News

Graf 47. prikazuje prosječne SO komentara u kategoriji Odgovornost iz kojeg se uočava da je najmanje odgovornim ocijenjen Ivo Baldasar, zatim Tomislav Zaninović, Marijo Popović, Damir Vidošević, Sanja Bilač i Željko Kerum. Kao najviše odgovorna ocijenjena je Anđelka Visković koja je uz Vjeksolava Ivanišević imala pozitivnu prosječnu SO komentara u ovoj kategoriji. Preostali kandidati u ovoj kategoriji nisu bili komentirani ili je ukupna SO komentara s obzirom na ovu odliku bila nula.



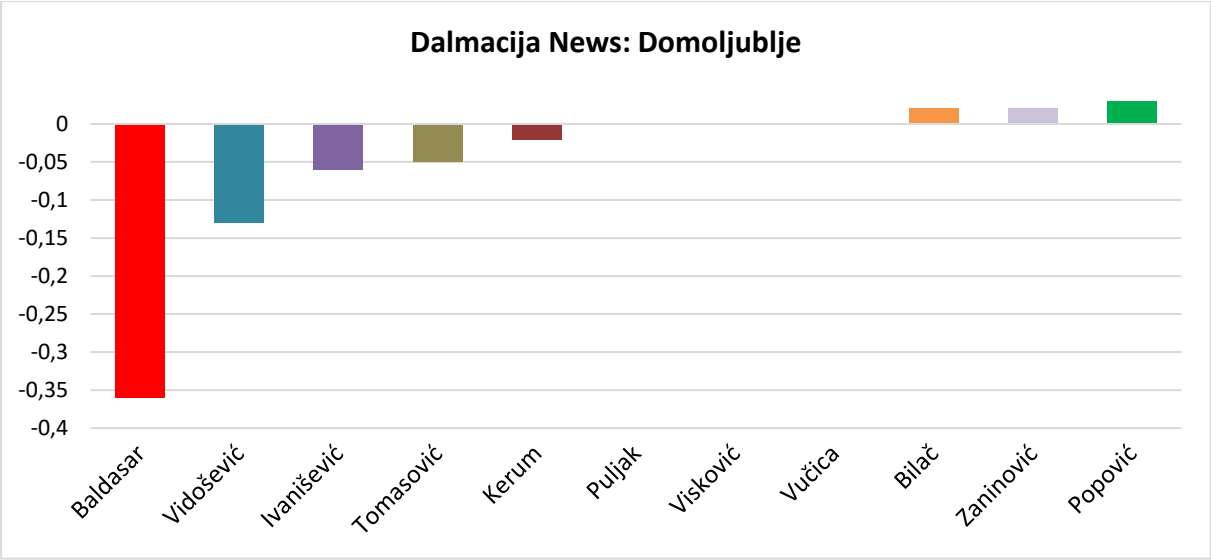
Graf 48. Prosječna SO komentara o moralnosti kandidata na portalu Dalmacija News

Graf 48. prikazuje prosječne SO komentara u kategoriji Moralnost iz kojeg se uočava da je najmanje moralnim ocijenjena Anđelka Visković, a sličan je rezultat imao i Ivo Baldasar. Nijedan kandidat u ovoj kategoriji nije imao pozitivnu prosječnu SO komentara.



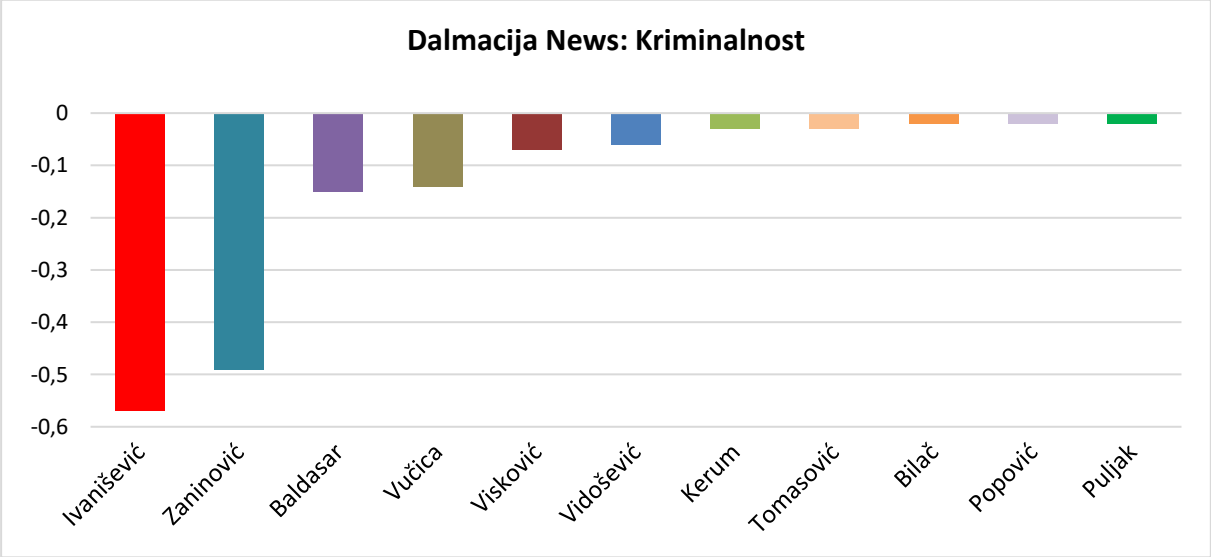
Graf 49. Prosječna SO komentara o izgledu kandidata na portalu Dalmacija News

Graf 49. prikazuje prosječne SO komentara u kategoriji Izgled iz kojeg se uočava da je u ovoj kategoriji jedina pozitivno ocijenjena Sanja Bilač. Vučica je imao najslabiji rezultat, ali budući da je o njemu bilo malo komentara njegov se rzeultat ne može smatrati statistički važnim. Nakon Vučice je najslabije ocijenjen Ivanišević, zatim Kerum, Baldasar, Popović, Zaninović i Visković. Preostali kandidati u ovoj kategoriji nisu bili komentirani ili je ukupna SO komentara s obzirom na ovu odliku bila nula.



Graf 50. Prosječna SO komentara o domoljublju kandidata

Graf 50. prikazuje prosječne SO komentara u kategoriji Domoljublje iz kojeg se uočava da je u ovoj kategoriji najbolje ocijenjen Marijo Popović, zatim Tomislav Zaninović i Sanja Bilač, koji su uz Popovića također imali pozitivne prosječne SO komentara u ovoj kategoriji. Najslabije je u ovoj kategoriji ocijenjen Ivo Baldasar, zatim Damir Vidošević, Vjekoslav Ivanišević, Hrvoje Tomasović i Željko Kerum. Preostali kandidati u ovoj kategoriji nisu bili komentirani ili je ukupna SO komentara s obzirom na ovu odliku bila nula.



Graf 51. Prosječna SO komentara o kriminalnosti kandidata na portalu Dalmacija News

Graf 51. prikazuje prosječne SO komentara u kategoriji Kriminalnost iz kojeg se uočava su u ovoj kategoriji za sve kandidate prosječne SO komentara negativne, a najslabije je ocijenjen Vjekoslav Ivanišević, a sličan rezultat ima i Tomislav Zaninović.

Analizom SO komentara, u odnosu na različite odlike kandidata, može se utvrditi da prevladavaju negativni stavovi, da su se građani novinari najviše negativno izražavali o kandidatima u kategorijama Moralnost i Kriminalnost.

3.6.3. Odlike konverzacije

Tablica 34. Centralne vrijednosti razine polemičnosti, interaktivnosti i argumentiranosti na portalu Dalmacija News

	a	i	rp
Med	0,00%	14,29%	2,000
Mod	0,00%	0,00%	2,000
Mean	9,15%	20,59%	1,893

Tablica 34. prikazuje rezultate dobivene za centralne vrijednosti razine polemičnosti, argumentiranosti i interaktivnosti komentara na članke. Medijan za interaktivnost iznosio je 14,29 %, za argumentiranost 0%, a za razinu polemičnosti 1,167. Niska razina polemičnosti i argumentiranosti upućuje na zaključak da je na portalu Dalmacija News komunikacija građana novinara imala odlike niske razine javne rasprave.

3.6.4. Teme, sentimenti i polemičnost konverzacije

Tablica 35. Popis novinskih članaka i postotak pozitivnih komentara o kandidatima na novinskom portalu Dalmacija News

Tema	Pozitivni komentari
Ivanišević: Moji najdraži projekti	62,500%
Ivanišević: Križ na Marjanu	42,857%
Kerum: Otkrio spomenik dr. Franji Tuđmanu!	36,667%
Tomasović: Iznio svoju viziju Splita i pobrao ovacije	34,615%
Visković: Inspirira me Majka Terezija, a Biblija mi je najdraža knjiga	33,333%
Visković: Jaka sam, vidi se to po napadima na mene	32,000%
Kerum: Otvorio Zapadnu obalu: "Vječno će ostati Splićanima"	31,034%
Kerum: Počeli radovi za spomenik dr. Franji Tuđmanu	30,435%
Visković: Predlaže Kerumu sučeljavanje	30,000%
Ivanišević: Split nije zaslužio da bude teatar, a nakon ulaska u EU tražit ćemo prijevremene parlamentarne izbore!	29,412%

Tablica 35. prikazuje popis prvih deset novinskih članaka prema postotku pozitivnih komentara o kandidatima. Članak koji je imao najveći udio pozitivnih komentara (62,5%) bio je o Vjekoslavu Ivaniševiću, a nakon njega slijede članak u kojem Ivanišević brani ideju o postavljanja križa (42,86%) i članak o Kerumu i podizanju križa na Marjanu (36,67%).

Tablica 36. Popis novinskih članaka i postotak negativnih komentara o kandidatima na novinskom portalu Dalmacija News

Tema	Negativni komentari
Ivanišević: Split je potonuo u svemu, dublje ne može	100,00%
Zaninović: Objavio kandidaturu za splitskog gradonačelnika	84,00%
Popović: Najluđu stvar u životu sam napravio na svojoj krizmi	83,05%
Kerum: Opet ću se kandidirati za gradonačelnika Splita!	82,14%
Ivanišević: Pozvao "narodnjačku, demokršćansku i domoljubnu" opciju na koaliciju	78,57%
Kerum: Odbio sučeljavanje s Anđelkom Visković, Baldasarom i Ivaniševićem	74,29%
Kerum: Postavljen spomenik dr. Franji Tuđmanu	73,08%
Baldasar: Milanović - Baldasar je kao dizelaš, kad krene ne staje!	71,05%
Kerum: Zapadna obala se otvara 12. travnja	70,59%
Kerum: Otvorio Zapadnu obalu: "Vječno će ostati Splićanima"	68,97%

Tablica 36. prikazuje popis prvih deset novinskih članaka prema postotku negativnih komentara. Najviše negativnih komentara imao je članak o Vjekoslavu Ivaniševiću (84%), zatim o Tomislavu Zaninoviću (83,05%) i Mariju Popoviću (82,14%).

Tablica 37. Popis novinskih članaka i razina polemičnosti na novinskom portalu Dalmacija News

Tema	R_p
Zajedničko: Visković i HDZ o Kerumu	4,031
Zajedničko: O davanju kafića na Zapadnoj obali bratu Kerumove nevjenčane supruge	4,017
Kerum: O imenovanju HGS-ovaca u školske odbore	3,083
Baldasar: Ne volim samo kuhanu meduzu prelivenu šugom od crvenih algi	3,083
Zajedničko: Prikupljanje potpisa kandidatima za lokalne izbore	3,071
Ivanišević: Slaven Letica navija za pobjedu Vjekoslava Ivanišević	3,067
Zaninović: Nikada ne bih sudjelovao u gay paradi!	3,063
Visković: Kerum opet sabotira Hajduk!	3,059
Ivanišević: Križ na Marjanu	3,048
Zajedničko: Škorićev poziv za koaliciju svidio se svima osim HDSSD-u	3,042

Tablica 37. Prikazuje popis prvih deset novinskih članaka prema razini polemičnosti konverzacija koje su se razvile nakon objavljivanja članaka. Najveću razinu polemičnosti postigao je članak u kojem HDZ i Anđelka Visković komentiraju Keruma (4,031) i o davanju u koncesiju kafića na Zapadnoj obali bratu Kerumove nevjenčane supruge (4, 017).

3.7. Usporedba novinskih portala

Novinski portali uspoređeni su s obzirom na:

a) Broj objavljenih članaka o kandidatima
b) Zastupljenost komentara o pojedinim kandidatima i građanima novinarima
c) Broj građana novinara u konverzacijama
d) Semantičke orijentacija komentara i udio pozitivno i negativno orijentiranih građana novinara prema pojedinim kandidatima
e) Maksimalne i minimalne prosječne semantičke vrijednosti komentara po pojedinim kategorijama
f) Centralne vrijednosti za razinu argumentiranosti, interaktivnosti i polemičnosti

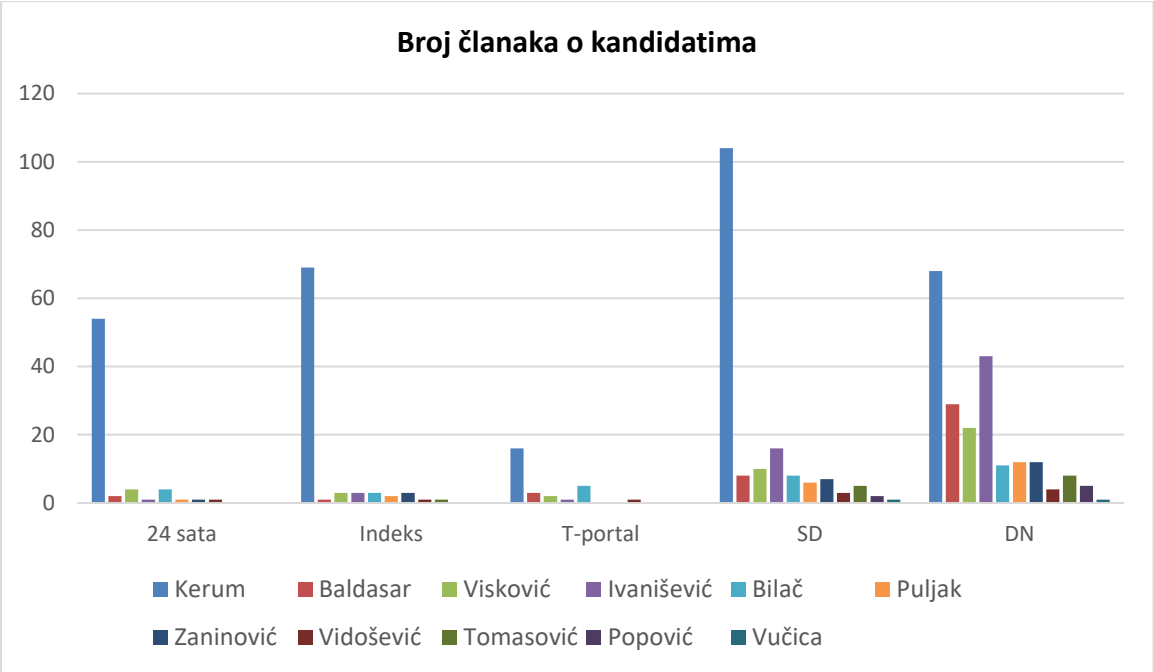
3.7.1. Broj objavljenih članaka o kandidatima

Tablica 38. Usporedba portala s obzirom na broj objavljenih članaka o kandidatima

	24 sata		*Indeks*		*T-portal*		*SD*		*DN*	
Kerum	54	79,41%	69	80,23%	16	57,14%	104	61,18%	68	32%
Baldasar	2	2,94%	1	1,16%	3	10,71%	8	4,71%	29	13%
Visković	4	5,88%	3	3,49%	2	7,14%	10	5,88%	22	10%
Ivanišević	1	1,47%	3	3,49%	1	3,57%	16	9,41%	43	20%
Bilač	4	5,88%	3	3,49%	5	17,86%	8	4,71%	11	5%
Puljak	1	1,47%	2	2,33%	0	0,00%	6	3,53%	12	6%
Zaninović	1	1,47%	3	3,49%	0	0,00%	7	4,12%	12	6%
Vidošević	1	1,47%	1	1,16%	1	3,57%	3	1,76%	4	2%
Tomasović	0	0,00%	1	1,16%	0	0,00%	5	2,94%	8	4%
Popović	0	0,00%	0	0,00%	0	0,00%	2	1,18%	5	2%
Vučica	0	0,00%	0	0,00%	0	0,00%	1	0,59%	1	0%
Ukupno	68		86		28		170		215	

Tablica 38. prikazuje broj objavljenih članaka o pojedinim kandidatima na različitim portalima. Razvidno je da je na svim portalima objavljeno najviše članaka o Željku Kerumu, s tim da je razlika između broja objavljenih članaka o tom kandidatu i o drugim kandidatima najmanje izražena na portalu Dalmacija News, a nešto se manja razlika uočava i na portalima Slobodna Dalmacija i T-portal. Broj objavljenih članaka o Vjekoslavu Ivaniševiću bio je na drugom mjestu na sljedećim portalima: Slobodna Dalmacija, Dalmacija News i Index.hr. Broj objavljenih članaka o Sanji Bilač bio je na drugom mjestu na T-portalu i portalu 24 sata. Broj objavljenih članaka o Anđelki Visković bio je na drugom mjestu na portalima Index i 24 sata. Broj objavljenih članaka o Ivi Baldasaru bio je na trećem mjestu na portalima: Dalmacija News i T-portal. Samo su portali Slobodna Dalmacija i Dalmacija News imali objavljene članke o svim kandidatima.

Najviše članaka koji su se odnosili na izbor splitskog gradonačelnika bilo je na portalu Dalmacija News (215), koji je ujedno i najmanje posjećen portal, a nakon njega na portalu Slobodna Dalmacija (170). Najmanje članaka bilo je na T-portalu (28).



Graf 52. Broj članaka o kandidatima na različitim portalima

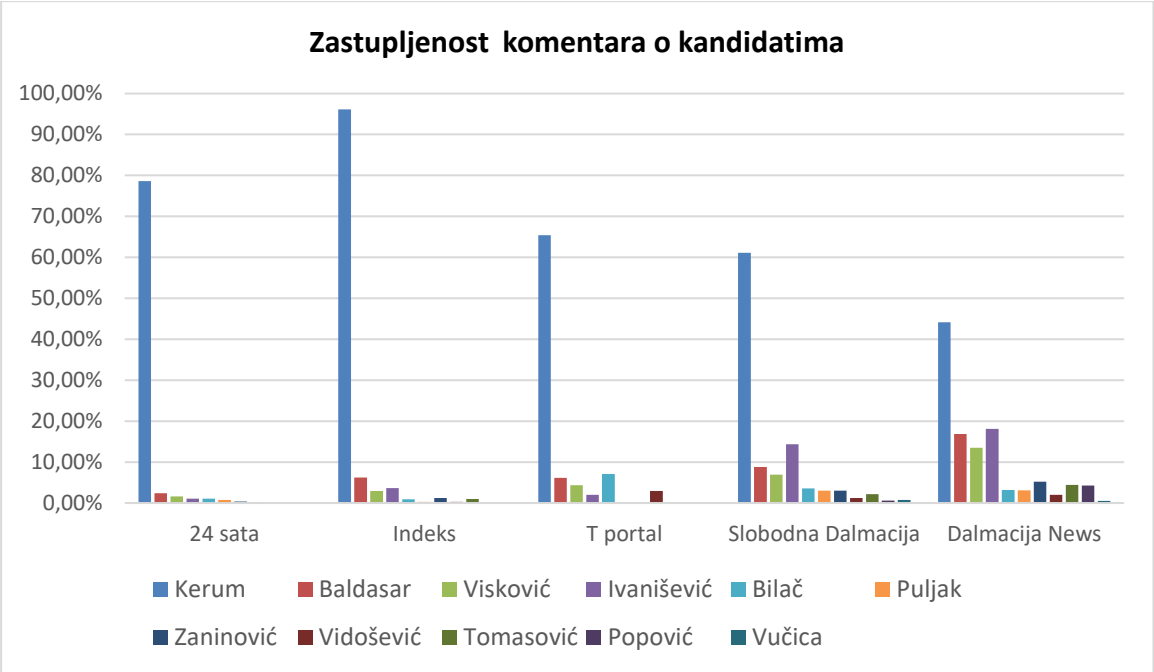
Graf 52. prikazuje broj članaka o pojedinim kandidatima na istraživanim portalima. Razvidno je da je na svim portalima objavljeno najviše članaka o Željku Kerumu, s tim da je razlika između broja objavljenih članaka o tom kandidatu i o drugim kandidatima najmanje izražena na portalu Dalmacija News, a nešto se manja razlika uočava i na portalima Slobodna Dalmacija i T-portal. Zajedničko je na svim portalima da imaju najveću zastupljenost članaka o Željku Kerumu, ali zastupljenost članaka o drugim kandidatima razlikuje se od portala do portala. Najmanja razlika u zastupljenosti članaka o različitim kandidatima uočava se na portalu Dalmacija News. Ukupno najviše članaka o svim kandidatima objavio je najmanje posjećen portal Dalmacija News, a najmanje članaka objavio je T-portal.

3.7.2. Zastupljenost komentara o kandidatima i građanima novinarima

Tablica 39. Usporedba portala s obzirom na zastupljenost komentara

	24 sata	Indeks	T portal	Slobodna Dalmacija	Dalmacija News
Br. kom.	5775	3115	786	4465	1963
Kerum	78,63%	96,15%	65,39%	61,12%	44,17%
Baldasar	2,42%	6,26%	6,11%	8,78%	16,86%
Visković	1,59%	2,92%	4,33%	6,94%	13,50%
Ivanišević	1,06%	3,63%	2,04%	14,33%	18,14%
Bilač	1,09%	0,90%	7,12%	3,56%	3,16%
Puljak	0,74%	0,29%	0,00%	3,02%	3,06%
Zaninović	0,38%	1,25%	0,00%	3,00%	5,20%
Vidošević	0,14%	0,26%	2,93%	1,25%	2,04%
Tomasović	0,00%	0,96%	0,00%	2,15%	4,43%
Popović	0,00%	0,00%	0,00%	0,56%	4,28%
Vučica	0,00%	0,00%	0,00%	0,72%	0,51%
Građani novinari	10,18%	16,85%	19,59%	24,59%	14,57%

Iz tablice 39. razvidno je da su na svim portalima izrazito najzastupljeniji komentari o Željku Kerumu, s tim da je to najviše naglašeno na Index portalu na kojem se 96,15% komentara odnosilo na njega. Najmanja razlika između zastupljenosti komentara o Željku Kerumu i drugim kandidatima bila je na portalu Dalmacija News, na kojem se 44,17% komentara odnosilo na Keruma. Na portalima 24 sata i Indeks, nakon komentara o Kerumu, bili su najzastupljeniji komentari o Ivi Baldasaru (2,42% i 6,26%). Na portalu 24 sata na trećem mjestu po zastupljenosti bili su komentari o Anđelki Visković (1,59%), a na portalu Index o Vjekoslavu Ivaniševiću (3,63%). Na T-portalu, nakon komentara o Kerumu, najzastupljeniji su bili komentari o Sanji Bilač (7,12%), a zatim o Ivi Baldasaru (6,11%). Na portalima Slobodna Dalmacija i Dalmacija News, nakon komentara o Kerumu, najviše je bilo komentara o Vjekoslavu Ivaniševiću (14,33% i 18,14%), a nakon njega o Ivi Baldasaru (8,78% i 16,86%). Najveća zastupljenost komentara, koji su se odnosili na građane novinare, uočena je na portalu Slobodna Dalmacija, na kojem se gotovo četvrtina svih komentara (24,59%) odnosila na građane novinare. Najmanja zastupljenost komentara koji su se odnosili na građane novinare uočena je na portalu 24 sata (10,18%).



Graf 53. Prikaz zastupljenosti komentara na istraživanim portalima

Graf 53. prikazuje broj komentara o pojedinim kandidatima i građanima novinarima. Zajedničko je na svim portalima da imaju najveću zastupljenost komentara o Željku Kerumu, ali zastupljenost komentara o drugim kandidatima razlikuje se od portala do portala. Najmanja razlika u zastupljenosti komentara o Željku Kerumu i drugim kandidatima uočava se na portalu Dalmacija News, a najveća na portalu Index. Zastupljenost komentara koji se odnose na građane novinare razlikuje se od portala do portala. Najviše je komentara o građanima novinarima bilo na portalu Slobodna Dalmacija, a najmanja na portalu 24 sata.

3.7.3. Broj građana novinara

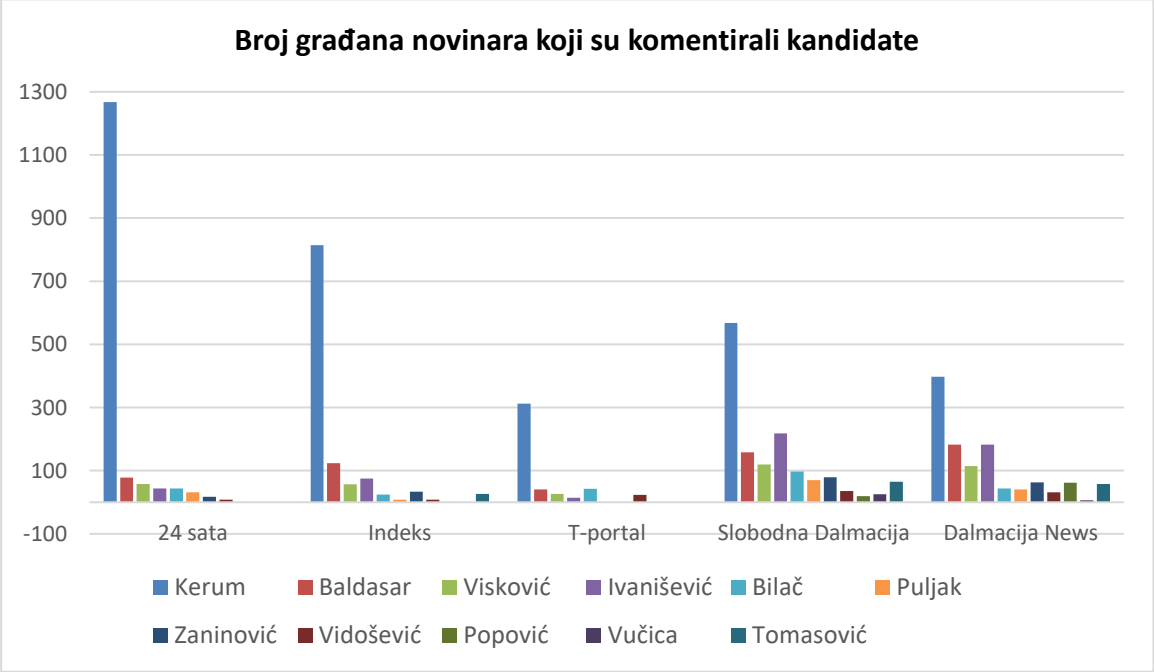
Tablica 40. Prikaz broja građana novinara na istraživanim portalima

	24 sata		*Indeks*		*T-portal*		*Slobodna Dalmacija*		*Dalmacija News*	
Kerum	1268	97,39%	814	84,09%	312	84,32%	568	89,73%	398	59,94%
Baldasar	78	5,99%	124	12,81%	41	11,08%	158	24,96%	183	27,56%
Visković	58	4,45%	57	5,89%	26	7,03%	120	18,96%	115	17,32%
Ivanišević	44	3,38%	75	7,75%	14	3,78%	218	34,44%	183	27,56%
Bilač	44	3,38%	24	2,48%	43	11,62%	97	15,32%	44	6,63%
Puljak	32	2,46%	8	0,83%	0	0,00%	70	11,06%	41	6,17%
Zaninović	17	1,31%	34	3,51%	0	0,00%	79	12,48%	63	9,49%
Vidošević	8	0,61%	8	0,83%	23	6,22%	36	5,69%	31	4,67%
Popović	0	0,00%	0	0,00%	0	0,00%	19	3,00%	62	9,34%
Vučica	0	0,00%	0	0,00%	0	0,00%	25	3,95%	6	0,90%
Tomasović	0	0,00%	26	2,69%	0	0,00%	65	10,27%	58	8,73%
Građani n.	297	22,81%	217	22,42%	81	21,89%	219	34,60%	150	22,59%
Ukupno	1302		968		370		633		664	

Tablica 40. prikazuje broja građana novinara koji su komentirali pojedinog kandidata i druge građane novinare na istraživanim portalima. Razvidno je da se na svim portalima najviše građana novinara uključilo u konverzaciju o kandidatu Željku Kerumu, što je najizraženije na portalu 24 sata (97,39%), a najmanje je izraženo na portalu Dalmacija News (59,94%). Kandidat Ivo Baldasar najviše je zainteresirao za konverzaciju korisnike portala Dalmacija News (27,56%) i Slobodna Dalmacija (24,96%), a bio je drugi najkomentiraniji kandidat na portalima 24 sata (5,99%), Index (12,81%) i Dalmacija News (27,56%). O kandidatkinji Anđelki Visković najviše se stupalo u konverzaciju na portalu Slobodna Dalmacija (18,96%) i Dalmacija News (17,32%). O kandidatu Vjekoslavu Ivaniševiću najviše se stupalo u konverzaciju na portalu Slobodna Dalmacija (34,44%), zbog čega je on na tom portalu bio nakon Keruma najkomentiraniji kandidat, a na portalu Dalmacija News drugo mjesto po komentiranosti dijelio je s Ivom Baldasarom (27,56%). Sanja Bilač najviše je za konverzaciju zainteresirala korisnike na portalu Slobodna Dalmacija (15,32%) i T-portalu (11,62%), na kojem je bila najkomentiranija nakon Keruma. O Marijani Puljak (11,06%) i Tomislavu Zaninoviću (12,48%) najviše se stupalo u konverzaciju na portalu Slobodna Dalmacija. U konverzaciju o Damiru Vidoševiću najviše se uključilo korisnika T-portala (6,22%), a u konverzaciji o Mariju Popoviću, koji je bio komentiran samo na portalima Slobodna Dalmacija

i Dalmacija News, najviše su sudjelovali korisnici portala Dalmacija News (9,34%). Hrvoje Tomasović najviše je za konverzaciju zainteresirao korisnike portala Slobodna Dalmacija (10,27%). Pero Vučica bio je komentiran samo na portalima Slobodna Dalmacija (3,95%) i Dalmacija News (0,90%).

Ukupni broj građana novinara u konverzacijama bio je najveći na portalu 24 sata (1302), a potom na portalu Index (968). Budući da je portal Index imao veći ukupni broj objavljenih članaka o kandidatima i budući da su oba portala imala sličan broj mjesečnih korisnika (oko milijun), može se zaključiti da je u odnosu na portal Index veći broj korisnika portala 24 sata pokazao interes za konverzaciju o izboru splitskog gradonačelnika. Zanimljivo je da je na portalu Dalmacija News bio veći broj građana novinara (664) u konverzacijama nego li na portalu Slobodna Dalmacija (633), premda je portal Slobodna Dalmacija trostruko posjećeniji od portala Dalmacija News. Također, kad se uzme u obzir da je Dalmacija News bio deset puta manje posjećen portal od portala 24 sata i Index, a da je broj građana novinara u konverzacijama samo dvostruko manji, može se zaključiti da su korisnici portala Dalmacija News pokazali najveći interes za sudjelovanje u konverzacijama o kandidatima za izbor splitskog gradonačelnika. Najmanje građana novinara u konverzacijama o kandidatima za splitskog gradonačelnika bilo je na T-portalu (370), što je vjerojatno povezano i s činjenicom da je ovaj portal imao najmanje članaka o toj temi.



Graf 54. Prikaz broja građana novinara koji su komentirali kandidate na istraživanim portalima

Graf 54. prikazuje komentiranost kandidata na istraživanim portalima. Na svim portalima najviše se građana novinara uključilo u konverzaciju o Željku Kerumu, dok se broj građana novinara u konverzacijama o ostalim kandidatima razlikuje od portala do portala. Dakako da je ovaj rezultat očekivano sličan onome koji se dobio za broj članaka objavljenih o pojedinom kandidatu na različitim portalima. Korisnici su portala Dalmacija News, kada se uzme u obzir posjećenost portala i ukupni broj građana novinara u konverzacijama, pokazali najveću zainteresiranost za sudjelovanje u konverzacijama o kandidatima za izbor splitskog gradonačelnika.

3.7.4. Analiza sentimenata

U usporedbi rezultata s obzirom na centralne vrijednosti SO komentara i udio pozitivno i negativno orijentiranih građana novinara u konverzacijama o pojedinim kandidatima ili drugim građanima novinarima uzeti su u obzir samo oni portali kod kojih je o pojedinom kandidatu bilo barem 20 korisnika portala koji su komentirali kandidata. Usporedba je izvršena za svakog kandidata posebno. Za centralne vrijednosti uzete su varijable prosječne vrijednosti i medijana.

Tablica 41. Centralne vrijednosti SO (Ker) i udio prema kandidatu pozitivno i negativno orijentiranih građana novinara

Željko Kerum	*Avg SO*	*Med SO*	*Poz*	*Neg*
24 sata	-4,56	-2	15,22%	75,71%
Indeks	-4,21	-1	14%	71%
T portal	-1,83	-1	22%	68%
Slobodna Dalmacija	-10,36	-2	24%	73%
Dalmacija News	-2,88	-1	27%	68%

Tablica 41. prikazuje centralne vrijednosti SO komentara za Željka Keruma i udio prema njemu pozitivno i negativno orijentiranih građana novinara na istraživanim portalima. Uočava se da je Željko Kerum najnižu prosječnu SO komentara imao na portalu Slobodna Dalmacija (-10,36) i da se najveći postotak građana novinara o njemu negativno izjašnjavao na portalu 24 sata (75,71%). S druge pak strane najviše je prema njemu pozitivno orijentiranih građana novinara bilo na portalu Dalmacija News (27%), ali sličan udio pozitivno orijentiranih građana novinara imao je i na portalu Slobodna Dalmacija (24%). Na portalima 24 sata i Index

bio je manji postotak građana novinara koji su se prema Kerumu pozitivno izjašnjavali u odnosu na ostale istraživane portale, s tim da je najmanje prema Kerumu pozitivno orijentiranih građana novinara bilo na portalu Index (14%).

Može se zaključiti da je među korisnicima portala Index i 24 sata koji su komentirali Željka Keruma bilo najmanje onih koji su o njemu imali pozitivan stav. Kerumu su bili najskloniji građani novinari na portalima Slobodna Dalmacija i Dalmacija News, a najmanje su mu bili skloni građani novinari na portalima Index i 24 sata.

Tablica 42. Centralne vrijednosti SO (Bal) i udio prema kandidatu pozitivno i negativno orijentiranih građana novinara

Ivo Baldasar	*Avg SO*	*Med SO*	*Poz*	*Neg*
24 sata	-2,41	-1	2,74%	93,15%
Indeks	-1,9	-1	19%	77%
T portal	-1,98	-1	5%	88%
Slobodna Dalmacija	-6,3	-2	10%	89%
Dalmacija News	-3,42	-2	11%	85%

Tablica 42. prikazuje centralne vrijednosti SO komentara za Ivu Baldasara i udio prema njemu pozitivno i negativno orijentiranih građana novinara na istraživanim portalima. Razvidno je da se najveći broj građana novinara o njemu negativno izjašnjavao na portalu 24 sata (93,15%), gdje je bilo i najmanje onih koji su o njemu imali pozitivan stav (2,74%). Najviše prema njemu pozitivno orijentiranih građana novinara (19%) i istodobno najmanje negativno orijentiranih (77%) imao je na portalu Index. Na portalima Slobodna Dalmacija i Dalmacija News mnijenje građana novinara o Baldasaru bilo je slično, s time da je na portalu Slobodna Dalmacija najviše negativno izražena prosječna vrijednost SO komentara o njemu (-6,3), što ukazuje na postojanje izrazito prema Baldasaru negativno orijentiranih građana novinara na ovom portalu.

Može se zaključiti da su Baldasaru bili najskloniji građani novinari na portalu Index, a najmanje skloni bili su mu građani novinari na portalu 24 sata.

Tablica 43. Centralne vrijednosti SO (Vis) i udio prema kandidatkinji pozitivno i negativno orijentiranih građana novinara

Anđelka Visković	*Avg SO*	*Med SO*	*Poz*	*Neg*
24 sata	-1,741	-2	12,28%	84,21%
T portal	-1,68	-1	4%	88%
Slobodna Dalmacija	-5,12	-2	11%	85%
Dalmacija News	-1,39	-1	26%	70%
Index	-0,53	-1	29%	53%

Tablica 43. prikazuje centralne vrijednosti SO komentara za Anđelku Visković i udio prema njoj pozitivno i negativno orijentiranih građana novinara na istraživanim portalima. Uočava se da je prema Anđelki Visković najviše pozitivno orijentiranih građana novinara bilo na portalu Index (29%), gdje je bio i najmanji udio prema njoj negativno orijentiranih građana novinara (53%). Najmanje prema njoj pozitivno orijentiranih građana novinara bilo je na T-portalu (4%), gdje je bio i najveći udio prema njoj negativno orijentiranih građana novinara (88%). I za nju je najizraženija negativna prosječna SO komentara uočena na portalu Slobodna Dalmacija (-5,12), što ukazuje na postojanje izrazito prema njoj negativno orijentiranih građana novinara na ovom portalu. Građani novinari na portalima Slobodna Dalmacija i 24 sata bili su sličnih orijentacija prema kandidatkinji.

Može se zaključiti da su Visković bili najskloniji građani novinari na portalu Index, a najmanje skloni bili su građani novinari na T-portalu.

Tablica 44. Centralne vrijednosti SO (Iva) i udio prema kandidatu pozitivno i negativno orijentiranih građana novinara

Vjekoslav Ivanišević	*Avg SO*	*Med SO*	*Poz*	*Neg*
24 sata	-1,273	-1	14,29%	76,19%
Indeks	-2,53	-2	7%	89%
Slobodna Dalmacija	-8,54	-1	10%	88%
Dalmacija News	-2,77	-1	23%	74%

Tablica 44. prikazuje centralne vrijednosti SO komentara za Vjekoslava Ivanišević i udio prema njemu pozitivno i negativno orijentiranih građana novinara na portalima na kojima je kandidata komentiralo barem 20 građana novinara. Uočava se da je prema Vjekoslavu

Ivaniševiću najviše pozitivno orijentiranih građana novinara bilo na portalu Dalmacija News (23%), a najmanje na portalu Index (7%). Na portalu Index bilo je i najviše prema njemu negativno orijentiranih građana novinara (89%). Sličan rezultat uočen je i na portalu Slobodna Dalmacija, na kojem je bilo 10 % prema njemu pozitivno orijentiranih građana novinara te 88% prema njemu negativno orijentiranih građana novinara. I za njega je najizraženija negativna prosječna SO komentara uočena na portalu Slobodna Dalmacija (-8,54), što ukazuje na postojanje izrazito prema njemu negativno orijentiranih građana novinara na ovom portalu.

Može se zaključiti da su Ivaniševiću bili najskloniji građani novinari na portalu Dalmacija News, a najmanje su mu bili skloni građani novinari na portalima Index i Slobodna Dalmacija.

Tablica 45. Centralne vrijednosti SO (Bil) i udio prema kandidatkinji pozitivno i negativno orijentiranih građana novinara

Sanja Bilač	*Avg SO*	*Med SO*	*Poz*	*Neg*
24 sata	-1,114	-1	15,00%	77,50%
Indeks	-0,79	-0,5	21%	50%
T portal	-0,71	-1	28%	60%
Slobodna Dalmacija	-2,38	-1	24%	74%
Dalmacija News	-1,05	-1	30%	68%

Tablica 45. prikazuje centralne vrijednosti SO komentara za Sanju Bilač i udio prema njoj pozitivno i negativno orijentiranih građana novinara na istraživanim portalima. Uočava se da je najviše prema Sanji Bilač pozitivno orijentiranih građana novinara bilo na portalu Dalmacija News (30%) i T-portalu (28%), a najmanje na portalu 24 sata (15%). Na portalu 24 sata bilo je najviše prema njoj negativno orijentiranih građana novinara (77,50%). No zanimljivo je da je najmanje prema njoj negativno orijentiranih građana novinara bilo na portalu Index (50%). I za nju je najizraženija negativna prosječna SO komentara uočena na portalu Slobodna Dalmacija (-2,38), što ukazuje na postojanje izrazito prema njoj negativno orijentiranih građana novinara na ovom portalu.

Može se zaključiti da su Bilač bili najskloniji građani novinari na T-potalu i Dalmacija News, a najmanje skloni bili su građani novinari na portalu 24 sata.

Tablica 46. Centralne vrijednosti SO (Pulj) i udio prema kandidatkinji pozitivno i negativno orijentiranih građana novinara

Marijana Puljak	*Avg SO*	*Med SO*	*Poz*	*Neg*
24 sata	0,324	0	50,00%	43,75%
Slobodna Dalmacija	2,89	-1	36%	58%
Dalmacija News	-0,22	0	49%	39%

Tablica 46. prikazuje centralne vrijednosti SO komentara za Marijanu Puljak i udio prema njoj pozitivno i negativno orijentiranih građana novinara na portalima na kojima je kandidatkinju komentiralo barem 20 građana novinara. Uočava se da je najviše prema Marijani Puljak pozitivno orijentiranih građana novinara bilo na portalu 24 sata (50%), a sličan je udio prema njoj pozitivno orijentiranih građana novinara bio i na portalu Dalmacija News (49%). Najmanje prema njoj pozitivno orijentiranih građana novinara bilo je na portalu Slobodna Dalmacija (36%), gdje je ujedno bilo i najviše prema njoj negativno orijentiranih građana novinara (58%). Za nju je najizraženija pozitivna prosječna SO komentara uočena na portalu Slobodna Dalmacija (2,89), što ukazuje na postojanje izrazito prema njoj pozitivno orijentiranih građana novinara na ovom portalu.

Može se zaključiti da su Puljak skloniji bili građani novinari na portalima 24 sata i Dalmacija News, a manje skloni bili su građani novinari na portalu Slobodna Dalmacija.

Tablica 47. Centralne vrijednosti SO (Zan) i udio prema kandidatu pozitivno i negativno orijentiranih građana novinara

Tomislav Zaninović	*Avg SO*	*Med SO*	*Poz*	*Neg*
Indeks	-0,76	-1	23%	68%
Slobodna Dalmacija	-4,91	-3	6%	91%
Dalmacija News	-2,7	-2	17%	81%

Tablica 47. prikazuje centralne vrijednosti SO komentara za Tomislava Zaninovića i udio prema njemu pozitivno i negativno orijentiranih građana novinara na portalima na kojima je kandidata komentiralo barem 20 građana novinara. Uočava se da je najviše prema Tomislavu Zaninoviću pozitivno orijentiranih građana novinara bilo na portalu Index (23%), a najmanje na portalu Slobodna Dalmacija (6%), gdje je ujedno bilo i najviše prema njemu negativno orijentiranih građana novinara (91%). I za njega je najizraženija negativna prosječna SO

komentara uočena na portalu Slobodna Dalmacija (-4,91), a i medijan je izraženo niži nego kod drugih portala i iznosi -3.

Može se zaključiti da su Zaninoviću bili skloniji građani novinari na portalu Index, a najmanje su mu bili skloni građani novinari na portalu Slobodna Dalmacija.

Tablica 48. Centralne vrijednosti SO (Vid) i udio prema kandidatu pozitivno i negativno orijentiranih građana novinara

Damir Vidošević	*Avg SO*	*Med SO*	*Poz*	*Neg*
T portal	-1,35	-1	9%	86%
Slobodna Dalmacija	-1,58	-1	19%	75%
Dalmacija News	-1,39	-1	16%	71%

Tablica 48. prikazuje centralne vrijednosti SO komentara o Damiru Vidoševiću i udio prema njemu pozitivno i negativno orijentiranih građana novinara na portalima na kojima je kandidata komentiralo barem 20 građana novinara. Uočava se da je prema Damiru Vidoševiću više pozitivno orijentiranih građana novinara bilo na portalima Slobodna Dalmacija (19%) i Dalmacija News (16%), a manje na T- portalu (9%), gdje je ujedno bilo i najviše prema njemu negativno orijentiranih građana novinara (86%).

Može se zaključiti da su Vidoševiću skloniji bili građani novinari na portalima Slobodna Dalmacija i Dalmacija News, a prema njemu bili su manje skloni građani novinari na T-portalu.

Tablica 49. Centralne vrijednosti SO (Tom) i udio prema kandidatu pozitivno i negativno orijentiranih građana novinara

Hrvoje Tomasović	*Avg SO*	*Med SO*	*Poz*	*Neg*
Indeks	-0,73	-1	11%	77%
Slobodna Dalmacija	-1,09	-2	18%	82%
Dalmacija News	-0,09	0	43%	45%

Tablica 49. prikazuje centralne vrijednosti SO komentara za Hrvoja Tomasovića i udio prema njemu pozitivno i negativno orijentiranih građana novinara na portalima na kojima je kandidata komentiralo barem 20 građana novinara. Uočava se da je prema Hrvoju Tomasoviću najviše pozitivno orijentiranih građana novinara bilo na portalu Dalmacija News (43%), a kudikamo manje na portalima Index (11%) i Slobodna Dalmacija (18%). Na portalu Slobodna Dalmacija medijan SO komentara bio je najniži (-2), a na tom portalu bio je i najveći udio

prema njemu negativno orijentiranih građana novinara, pa se može zaključiti da su mu na tom portalu građani novinari bili najmanje skloni.

Može se zaključiti da su Tomasoviću skloniji bili građani novinari na portalu Dalmacija News, a najmanje su mu skloni bili građani novinari na portalu Slobodna Dalmacija.

Tablica 50. Centralne vrijednosti SO (Pop) i udio prema kandidatu pozitivno i negativno orijentiranih građana novinara

Marijo Popović	*Avg SO*	*Med SO*	*Poz*	*Neg*
Slobodna Dalmacija	-2,74	-2	0%	95%
Dalmacija News	-1,95	-1,5	16%	79%

Tablica 50. prikazuje centralne vrijednosti SO komentara za Marija Popovića i udio prema njemu pozitivno i negativno orijentiranih građana novinara na portalima na kojima je kandidat komentiran. Dalmacija uopće nije bilo prema njemu pozitivno orijentiranih građana novinara, a 95% je bilo negativno orijentirano. Sve su centralne vrijednosti SO komentara negativne, a budući da je samo 19 građana novinara na portalu Slobodna Dalmacija komentiralo kandidata ne može se izvršiti statistički relevantna usporedba.

Tablica 51. Centralne vrijednosti SO (Vuč) i udio prema kandidatu pozitivno i negativno orijentiranih građana novinara

Pero Vučica	*Avg SO*	*Med SO*	*Poz*	*Neg*
Slobodna Dalmacija	-3,08	-2	0%	100%
Dalmacija News	-3	-3	0%	100%

Tablica 51. prikazuje centralne vrijednosti SO komentara za Peru Vučicu i udio prema njemu pozitivno i negativno orijentiranih građana novinara na portalima na kojima je kandidat bio komentiran. Sve su centralne vrijednosti SO komentara negativne, a budući da je samo 6 građana novinara na portalu Dalmacija News komentiralo kandidata ne može se izvršiti statistički relevantna usporedba.

Na temelju rezultata za centralne vrijednosti SO komentara i udjela prema kandidatima pozitivno i negativno orijentiranih građana novinara može se zaključiti da su motivi građana za participaciju pretežito negativni stavovi prema kandidatima, zbog čega se prihvaća hipoteza H4. Ovom zaključku doprinosi i podatak da je u rječniku s riječima i izrazima koji izražavaju

sentimente bilo 77,32 % onih s negativnim predznakom za SO te 22, 68% onih s pozitivnim predznakom za SO.

Tablica 52. Centralne vrijednosti SO (Sud) i udio prema građanima novinarima pozitivno i negativno orijentiranih građana novinara

Građani novinari	Avg SO	Med SO	Poz	Neg
24 sata	-0,513	-1	37%	60%
Index	-2,41	-1	10%	87%
T-portal	-1,80	-1	16%	55%
Slobodna Dalmacija	-10	-4	9%	81%
Dalmacija News	-2,93	-2	9%	71%

Tablica 52. prikazuje centralne vrijednosti SO komentara koji se odnose na građane novinare i udio prema njima pozitivno i negativno orijentiranih građana novinara na istraživanim portalima. Uočava se da su stavovi građana novinara jedni prema drugima pretežito negativni, a negativnost je najizraženija na portalu Slobodna Dalmacija gdje je prosječna vrijednost SO komentara koji su se odnosili na građane novinare bila -10, a medijan -4. Također, na portalu Slobodna Dalmacija 81% građana novinara imalo je negativne stavove jedni o drugima. Izraženija negativna orijentacija uočena je i na portalu Index gdje je čak 87 % građana novinara imalo negativne stavove o drugim građanima novinarima, ali su centralne vrijednosti SO komentara koji su se odnosili na građane novinare bile niže. To upućuje na zaključak da je na portalu Slobodna Dalmacija bilo prema drugim građanima novinarima izrazito negativno orijentiranih građana novinara, što je utjecalo na visoke razine prosječne vrijednosti i medijana SO ovih komentara.

3.7.5. Odlike kandidata

Uspoređujući različite portale s obzirom na maksimalne i minimalne prosječne vrijednosti komentara po pojedinim kategorijama potrebno je uzeti u obzir da na svim portalima nisu komentirani svi kandidati, niti da je za sve kandidate postojao dovoljan broj komentara na temelju kojeg bi se rezultati mogli smatrati statistički važnima.

Tablica 53. Maksimalne i minimalne prosječne semantičke vrijednosti komentara po pojedinim kategorijama

	24 sata	*Indeks*	*T portal*	*Slobodna Dalmacija*	*Dalmacija News*
PO max	Pulj (0,34)	Pulj (0,5)		Pulj (0,8)	Tom (0,34)
PO min	Ker (-1,42)	Ker (-1,36)	Bal (-1,1)	Ker (-3,11)	Bal (-1,36)
SP max	Pulj (0,06)	Pulj (0,38)		Pulj (1,01)	Vis, Tom (0,5)
SP min	Ker (-0,48)	Ker (-0,33)	Ker, Vis (-0,23)	Ker (-0,67)	Pop (-0,35)
IZ max	Vis, Bil (0,02)	Bil (0,04)	Bil (0,02)	Bil (0,09)	Bil (0,02)
IZ min	Ker (-0,21)	Ker (-0,12)	Ker (-0,04)	Ker (-0,09)	Iva (-1,13)
MO max		Pulj (0,25)		Pulj (0,06)	
MO min	Ker (-0,95)	Ker (-0,92)	Vis (-0,69)	Ker (-3,53)	Vis(-1,04)
PR max		Pulj (0,13)		Pulj (0,37)	
PR min	Ker (-0,37)	Ker (-0,63)	Ker (-0,17)	Ker (-0,97)	Pop (-0,18)
OD max		Pulj (0,25)		Pulj (0,1)	Vis (0,04)
OD min	Ker (-0,56)	Ker (-0,33)	Ker (-0,15)	Iva (-1,14)	Bal (-0,27)
DO max		Tom (0,12)		Tom (0,03)	Pop (0,03)
DO min	Bal (-0,27)	Bal (-0,1)	Bal (-0,1)	Bal (-0,66)	Bal (-0,36)
KR max					
KR min	Ker (-0,53)	Iva (-0,65)	Iva (-0,79)	Iva (-1,37)	Iva (-0,57)

U tablici 53. maksimalna prosječna SO komentara navedena je samo ukoliko je bila pozitivna i veća od nule. Unatoč manjkavostima ovakve usporedbe mogu se uočiti razlike, ali i sličnosti u maksimalnim i minimalnim prosječnim vrijednostima SO komentara po pojedinim kategorijama na različitim portalima.

Na portalima 24 sata, Index i Slobodna Dalamacija najviše je potpore u komentarima dobila Marijana Puljak, a na portalu Dalmacija News Hrvoje Tomasović. Najmanju potporu na portalima 24 sata, Index i Slobodna Dalmacija dobio je Željko Kerum, na T-portalu Ivo Baldasar, a na portalu Dalmacija News Pero Vučica. Međutim, za Peru Vučicu nije bilo dovoljno komentara na temelju kojih bi ta ocjena bila statistički važna, pa je kao najslabije ocijenjen kandidat na portalu Dalmacija News naveden Ivo Baldasar.

U kategoriji Sposobnost na portalima 24 sata, Index i Slobodna Dalmacija najbolje je bila ocijenjena Marijana Puljak, a na portalu Dalmacija News Anđelka Visković i Hrvoje Tomasović. Na portalima 24 sata, Index i Slobodna Dalmacija i T-portal najslabije je u toj kategoriji bio ocijenjen Željko Kerum, a na portalu Dalmacija News Mario Popović. Na T-portalu, uz Keruma, najslabije je u kategoriji Sposobnost bila ocijenjena i Anđelka Visković.

U kategoriji Izgled na svim je portalima najbolje ocijenjena Sanja Bilač, a na portalu 24 sata uz nju je najbolje u ovoj kategoriji bila ocijenjena i Anđelka Visković. Najlošije je u ovoj kategoriji na svim portalima bio ocijenjen Željko Kerum, osim na portalu Dalmacija News na kojem je najlošije u ovoj kategoriji bio ocijenjen Pero Vučica. Međutim, za Peru Vučicu nije bilo dovoljno komentara na temelju kojih bi ta ocjena bila statistički važna, pa je kao najslabije ocijenjen kandidat na portalu Dalmacija News naveden Vjekoslav Ivanišević.

U kategoriji Moralnost na portalima Index i Slobodna Dalmacija najbolje je bila ocijenjena Marijana Puljak. Na portalima Index, 24 sata i Slobodna Dalmacija najslabije je u ovoj kategoriji bio ocijenjen Željko Kerum, a na portalu Dalmacija News i T-portalu Anđelka Visković.

U kategoriji Pristojnost na portalima Index i Slobodna Dalmacija najbolje je bila ocijenjena Marijana Puljak. Na svim je portalima, osim na portalu Dalmacija News, u ovoj kategoriji najslabije bio ocijenjen Željko Kerum. Na portalu Dalmacija News najslabije je bio ocijenjen u ovoj kategoriji Marijo Popović.

U kategoriji Odgovornost na portalima Index i Slobodna Dalmacija najbolje je bila ocijenjena Marijana Puljak, a na portalu Dalmacija News Anđelka Visković. Na portalima 24 sata, Index i T-portal najslabije u ovoj kategoriji bio je ocijenjen Željko Kerum, na portalu Slobodna Dalmacija Vjekoslav Ivanišević, a na portalu Dalmacija News Ivo Baldasar.

Na portalima Index i Slobodna Dalmacija najbolje je u kategoriji Domoljublje bio ocijenjen Hrvoje Tomasović, a na portalu Dalmacija News Marijo Popović. Na svim je portalima najslabije bio ocijenjen Ivo Baldasar.

U kategoriji Kriminalnost nijedan kandidat nije bio pozitivno ocijenjen. Na portalu 24 sata najslabije je u ovoj kategoriji bio ocijenjen Željko Kerum, a na svim ostalim portalima Vjekoslav Ivanišević.

Usporedbom prosječnih vrijednosti SO komentara po pojedinim kategorijama mogu se na temelju komentara građana novinara na istraživanim portalima za neke kandidate uočiti njihovi tipični prednosti i nedostaci. Tipični nedostaci i prednosti navedeni su ukoliko su uočeni na barem dva portala. Za Sanju Bilač tipična je prednost dobar izgled, za Hrvoja Tomasovića domoljublje. Za Marijanu Puljak uočavaju se prednosti: sposobnost, moralnost, pristojnost i odgovornost. Za Vjekoslava Ivaniševića tipični je nedostatak kriminalnost, a za Ivu Baldasara

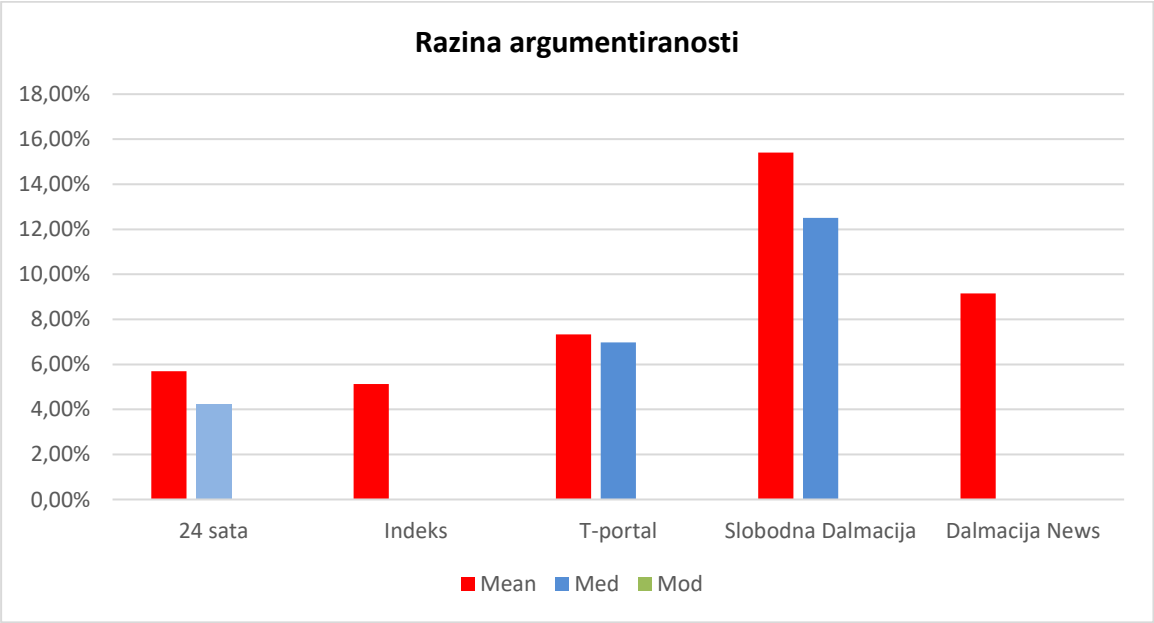
manjak domoljublja. Za Željka Keruma tipični su nedostaci: nesposobnost, nemoralnost, nepristojnost i neodgovornost te loš izgled.

3.7.6. Odlike konverzacije

Tablica 54. Centralne vrijednosti za argumentiranost konverzacija o kandidatima na istraživanim portalima

ARGUMENTIRANOST	*Med*	*Mod*	*Mean*
24 sata	4,26%	0,00%	5,69%
Indeks	0,00%	0,00%	5,13%
T-portal	6,98%	0,00%	7,33%
Slobodna Dalmacija	12,50%	0,00%	15,40%
Dalmacija News	0,00%	0,00%	9,15%

Tablice 54. prikazuje centralne vrijednosti za argumentiranost konverzacija na istraživanim portalima. Razvidno je da je najveća argumentiranost konverzacija o kandidatima bila na portalu Slobodna Dalmacija. Za taj se portal uočava najveći medijan (12,50%) i najveća prosječna vrijednost (15,40%) argumentiranosti. Najslabija argumentiranost konverzacija bila je na portalu Index, na kojem je najniža prosječna vrijednost (5,13%) i ujedno najniži medijan (0%) argumentiranosti. U odnosu na portal Indeks, portal Dalmacija News imao je višu prosječnu vrijednost argumentiranosti (9,15%), a ostale su vrijednosti bile iste, iz čega se da zaključiti da je na ovom portalu bilo više članaka s nešto izraženijom argumentiranošću u odnosu na portal Index.



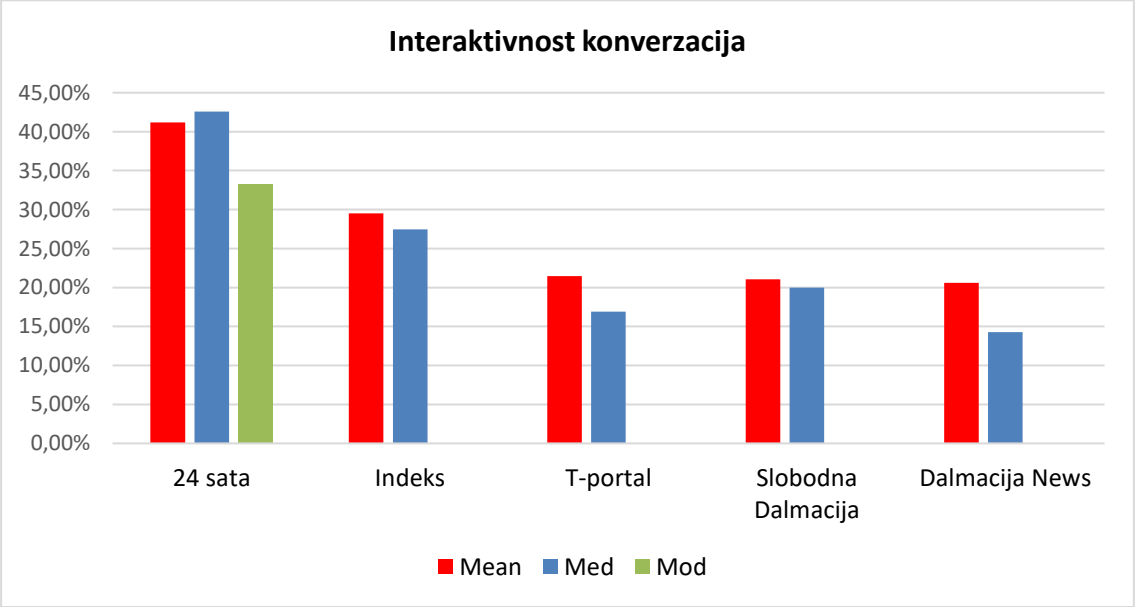
Graf 55. Argumentiranost konverzacija o kandidatima na istraživanim portalima

Graf 55. prikazuje razliku u argumentiranosti konverzacija o kandidatima na istraživanim portalima. Uočava se veća argumentiranost na portalu Slobodna Dalmacija.

Tablica 55. Centralne vrijednosti za interaktivnost građana novinara u konverzacijama o kandidatima na istraživanim portalima

INTERAKTIVNOST	*Med*	*Mod*	*Mean*
24 sata	42,58%	33,33%	41,19%
Indeks	27,45%	0,00%	29,53%
T-portal	16,90%	0,00%	21,47%
Slobodna Dalmacija	20,00%	0,00%	21,05%
Dalmacija News	14,29%	0,00%	20,59%

Tablice 55. prikazuje centralne vrijednosti za interaktivnost konverzacija na istraživanim portalima. Razvidno je da je najveća interaktivnost građana novinara u konverzacijama o kandidatima bila na portalu 24 sata. Za taj se portal uočava najveći medijan (42,58%), najveća prosječna vrijednost (41,19%) i najveći mod (33%) interaktivnosti. Najslabija interaktivnost građana novinara u konverzacijama bila je na portalu Dalmacija News, za koji je najniža prosječna vrijednost (20,59%) i ujedno najniži medijan (14,29%) interaktivnosti. No, slična i tek nešto bolja interaktivnost uočena je na T-portalu, na kojem je prosječna vrijednost interaktivnosti bila 21,47%, a medijan 16,90%.



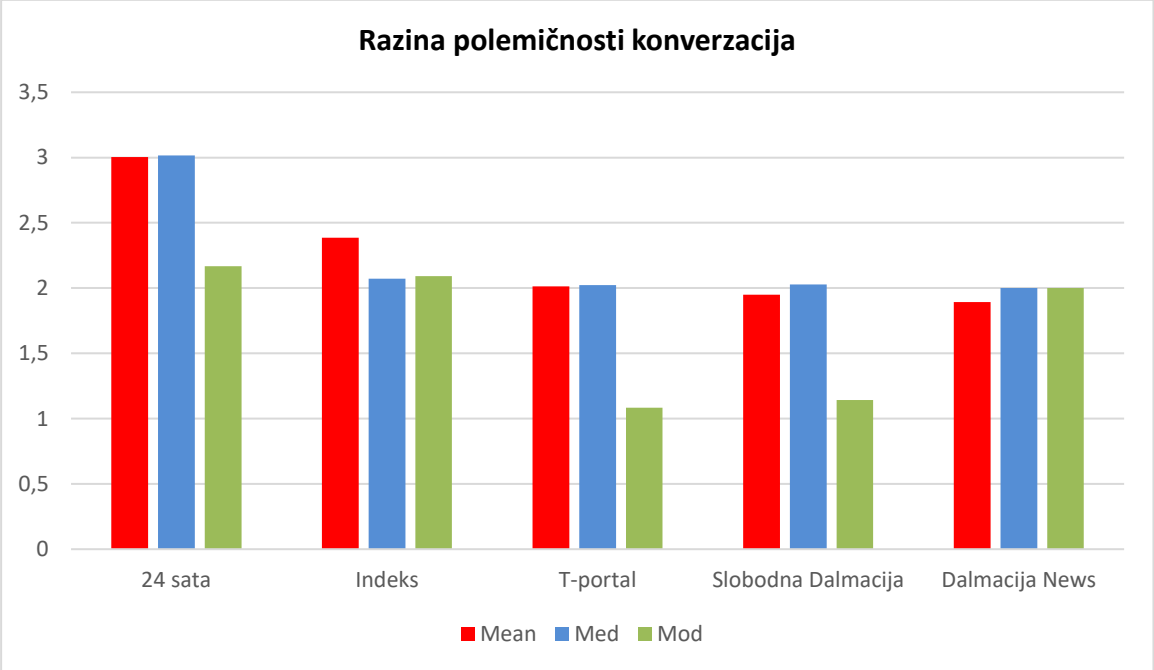
Graf 56. Interaktivnost građana novinara u konverzacijama o kandidatima na istraživanim portalima

Graf 56. prikazuje razliku u interaktivnosti građana novinara na istraživanim portalima. Uočava se veća interaktivnost na portalu 24 sata.

Tablica 56. Centralne vrijednosti za razinu polemičnosti u konverzacijama o kandidatima na istraživanim portalima

RAZINA POLEMIČNOSTI	*Med*	*Mod*	*Mean*
24 sata	3,016	2,167	3,004
Indeks	2,071	2,091	2,385
T-portal	2,023	1,083	2,014
Slobodna Dalmacija	2,029	1,143	1,949
Dalmacija News	2,000	2,000	1,893

Tablice 56. prikazuje centralne vrijednosti za razinu polemičnosti u konverzacijama o kandidatima na istraživanim portalima. Razvidno je da je najveća razina polemičnosti konverzacija o kandidatima bila na portalu 24 sata. Za taj se portal uočava najveći medijan (3,016), najveća prosječna vrijednost (3,004) i najveći mod (2,167) razine polemičnosti. Najslabija razina polemičnosti konverzacija bila je na portalu Dalmacija News, za koji je najniža prosječna vrijednost (1,893) i najniži medijan (2,000) razine polemičnosti.



Graf 57. Razina polemičnosti u konverzacijama o kandidatima na istraživanim portalima

Graf 57. prikazuje razliku u razini polemičnosti konverzacija o kandidatima na istraživanim portalima. Uočava se veća razina polemičnosti na portalu 24 sata.

Naposljetku se može uočiti da postoje razlike između portala s obzirom na pokazatelje kvalitete javne rasprave, da je najviše argumenata bilo u konverzacijama na portalu Slobodna Dalmacija te da je najveća interaktivnost i razina polemičnosti bila na portalu 24 sata. Budući da je portal 24 sata imao najveću vrijednost za dva pokazatelja (interaktivnost i razina polemičnosti) može se zaključiti da je na ovom portalu postignuta nešto veća razina javne rasprave u odnosu na ostale.

Tablica 57. Teme novinskih članaka s najvećim razinama polemičnosti konverzacija

Portal	*rp*	*Tema*
24 sata	7,005	Kerum: donacija redovnicama
	6,003	Kerum: spomenik Tuđmanu
	6,003	Kerum: optuživanje Grubišića
Index	8,005	Kerum: ustupanje stadiona Thompsonu
	6,006	Kerum: križ na Marjanu i spomenik Tuđmanu
T-portal	5,013	Kerum: križ na Marjanu
	3,043	Bilač: optuživanje Keruma
Slobodna Dalmacija	6,008	Kerum: spomenik Tuđmanu
	5,014	Zajedničko: Predviđanja rezultata izbora
Dalmacija News	4,031	Zajedničko: Visković i HDZ o Kerumu
	4,017	Zajedničko: O davanju kafića na Zapadnoj obali bratu Kerumove nevjenčane supruge

U tablici 57. navedene su teme novinskih članaka s najvećim razinama polemičnost na različitim portalima. Uočava se veća razina polemičnosti u konverzacijama koje su se odnosile na Kerumove postupke ustupanja stadiona Thompsonu, donacija redovnicama te podizanja spomenika Tuđmanu i križa na Marjanu.

Za sve istraživane portale može se kazati da je komunikacija građana novinara zbog niske razine polemičnosti i argumentiranosti imala **nisku razinu javne rasprave**, zbog čega se **prihvaća hipoteza H6**.

3.7.7. Sličnosti populacija korisnika na različitim portalima

Usporedba populacija korisnika portala izvršena je na temelju usporedbe raspodjele rezultata za varijable: SO (Ker), SO (Bil), SO (Bal) i SO (Sud) za koje je na istraživanim portalima bilo barem 20 ispitanika (građana novinara). Pri tom je odabran Kruskal - Wallis test, budući da su ostvarene pretpostavke za primjenu tog testa (Kruskal &Wallis, 1952):

a) raspodjela rezultata nije prema normalnoj distribuciji
b) ne postoji jednak broj ispitanika (građana novinara) na istraživanim portalima
c) rezultati su u obliku kontinuirane skale vrijednosti
d) na različitim portalima različiti su građani novinari (ispitanici)

Tablica 58. Rezultati Kruskal- Wallis testa za usporedbu raspodjela rezultata SO (Ker), SO (Bal), SO (Bil) i SO (Sud)

	p-value	*alpha*	*sig*
SO(S)	0,000	0,05	yes
SO(Bil)	0,039	0,05	yes
SO (Bal)	0,001	0,05	yes
SO (Ker)	0,000	0,05	yes

Tablica 58. prikazuje rezultate Kruskal-Wallis testa za usporedbu raspodjele rezultata za varijable SO (Ker), SO (Bal), SO (Bil) i SO (Sud). Razvidno je da postoji statistički značajna razlika u raspodjeli rezultata za sve varijable, pa se može zaključiti da na istraživanim portalima građani novinari koji su komentirali kandidate za izbor splitskog gradonačelnika **ne pripadaju istoj populaciji birača.** Ovim se rezultatom **odbacuje** peta hipoteza **H5** i zaključuje da **postoje statistički značajne razlike u semantičkoj orijentaciji komentara građana novinara** na istraživanim portalima.

3.7.8. Povezanost participativnog novinarstva i izbornih rezultata

Povezanost participativnog novinarstva i izbornih rezultata (Split: Konačni službeni rezultati izbora za gradonačelnika - 19. svibnja 2013.) utvrdila se pomoću koeficijenta korelacije između broja dobivenih glasova i varijabli kojima je u ovom istraživanju opisano participativno novinarstvo:

a) broj objavljenih članaka o kandidatu
b) broj prema kandidatu pozitivno i negativno orijentiranih građana komentatora
c) broj objavljenih komentara o kandidatu
d) broj građana novinara koji su komentirali kandidata

U istraživanju povezanosti izbornih rezultata i varijabli participativnog novinarstva uzeti su u obzir samo oni portali koji su o svim kandidatima objavili članke: Slobodna Dalmacija i Dalmacija News. Pri tom je kao pokazatelj povezanosti upotrijebljen Spearmanov

koeficijent korelacije ranga, budući da su ispunjeni preduvjeti za njegovu primjenu (Udovičić i dr., 2007):

a) raspodjela podataka značajno odstupa od normalne raspodjele
b) postoje podatci koji značajno odstupaju od većine izmjerenih
c) u uzorcima (istraživanim portalima) manje je od 35 podataka za uspoređivanje varijabli

Tablica 59. Povezanost broja objavljenih članaka i broja dobivenih glasova nakon prvog izbornoga kruga

Kandidat	*SD*	*DN*	*Broj glasova*
Kerum	104	68	13471
Baldasar	8	29	21280
Visković	10	22	5777
Ivanišević	16	43	15803
Bilač	8	11	1339
Puljak	6	12	6998
Zaninović	7	12	2115
Vidošević	3	4	1340
Tomasović	5	8	990
Popović	2	5	942
Vučica	1	1	1043
p value	0,004	0,000	
Alpha	0,05	0,05	
rho	0,75	0,84	

U tablici 59. u prvom su stupcu brojevi glasova koje su kandidati za splitskog gradonačelnika dobili nakon prvog izbornoga kruga, a u drugom su brojevi članaka o njima objavljeni na portalima Slobodna Dalmacija i Dalmacija News. Budući da vrijednosti koeficijenta rho od 0,50 do 0,75 upućuju na umjerenu do dobru povezanost varijabli, a vrijednosti od 0,75 do 1 upućuju na vrlo dobru do izvrsnu povezanost među varijablama te da je značajnost koeficijenta korelacije p manja od 0,05 (Udovičić i dr., 2007), može se zaključiti da postoji **vrlo dobra povezanost** između izbornih rezultata i broja objavljenih članaka o kandidatu na portalu **Slobodna Dalmacija** te **vrlo dobra povezanost** između izbornih rezultata i broja objavljenih članaka na portalu **Dalmacija News**.

Tablica 60. Povezanost između broja prema kandidatu pozitivno i negativno orijentiranih građana i broja dobivenih glasova nakon prvoga izbornoga kruga

Kandidat	*SD (+)*	*SD (-)*	*DN (+)*	*DN (-)*	*Broj glasova*
Kerum	135	417	107	271	13471
Baldasar	16	140	21	155	21280
Visković	13	102	30	80	5777
Ivanišević	22	191	42	135	15803
Bilač	23	72	13	30	1339
Puljak	25	41	20	16	6998
Zaninović	5	72	11	51	2115
Vidošević	7	27	5	22	1340
Tomasović	12	53	25	26	990
Popović	0	18	10	49	942
Vučica	0	25	0	7	1043
p value	0,014	0,002	0,023	0,019	
Alpha	0,05	0,05	0,05	0,05	
rho	0,66	0,79	0,61	0,63	

U tablici 60. u prvom je stupcu za svaki portal naveden broj prema kandidatu pozitivno orijentiranih građana novinara (+), u drugom prema kandidatu negativno orijentiranih građana novinara (-), a u zadnjem je broj dobivenih glasova nakon prvoga izbornoga kruga. S obzirom na dobivene vrijednosti rho i p, može se zaključiti da na portalu **Slobodna Dalmacija** postoji **dobra povezanost** izbornih rezultata i broja prema kandidatu **pozitivno orijentiranih** građana novinara kandidatu te **vrlo dobra povezanost** izbornih rezultata i broja prema kandidatu **negativno orijentiranih** građana novinara. Na portalu **Dalmacija News** postoji **dobra povezanost** između izbornih rezultata i prema kandidatu **pozitivno orijentiranih** građana novinara, kao i **dobra povezanost** između izbornih rezultata i prema kandidatu **negativno orijentiranih** građana novinara. Zbog toga se **prihvaća** druga hipoteza **H2** da na istraživanim novinskim portalima **postoji povezanost između broja građana novinara koji se pozitivno izjašnjavaju o kandidatu i izbornih rezultata** i treća hipoteza **H3** da na istraživanim novinskim portalima **postoji povezanost između broja građana novinara koji se negativno izjašnjavaju o kandidatu i izbornih rezultata.**

Tablica 61. Povezanost između broja komentara o kandidatu i broja dobivenih glasova nakon prvoga izbornoga kruga

Kandidat	*SD*	*DN*	*Broj glasova*
Kerum	2729	867	13471
Baldasar	392	331	21280
Visković	310	265	5777
Ivanišević	640	356	15803
Bilač	159	62	1339
Puljak	135	60	6998
Zaninović	134	102	2115
Vidošević	56	40	1340
Tomasović	96	87	990
Popović	25	84	942
Vučica	32	10	1043
p value	0,001	0,035	
Alpha	0,05	0,05	
rho	0,85	0,64	

U tablici 61. u prvom je stupcu za svaki portal naveden broj komentara o kandidatu, a u drugom broj dobivenih glasova nakon prvoga izbornoga kruga. S obzirom na dobivene vrijednosti rho i p, može se zaključiti da na portalu **Slobodna Dalmacija** postoji **vrlo dobra povezanost** izbornih rezultata i broja komentara o kandidatu. Na portalu **Dalmacija News** postoji **dobra povezanost** između izbornih rezultata i broja komentara o kandidatu.

Tablica 62. Povezanost između broja građana novinara koji su komentirali kandidata i broja dobivenih glasova nakon prvoga izbornoga kruga

Kandidat	*SD*	*DN*	*Broj glasova*
Kerum	568	398	13471
Baldasar	158	183	21280
Visković	120	115	5777
Ivanišević	218	183	15803
Bilač	97	44	1339
Puljak	70	41	6998
Zaninović	79	79	2115
Vidošević	36	31	1340
Tomasović	65	58	990
Popović	19	62	942
Vučica	25	6	1043
p value	0,001	0,018	
Alpha	0,05	0,05	
rho	0,84	0,63	

U tablici 62. u prvom je stupcu za svaki portal naveden broj građana novinara koji su komentirali kandidata, a u drugom broj dobivenih glasova nakon prvoga izbornoga kruga. S obzirom na dobivene vrijednosti rho i p, može se zaključiti da na portalu **Slobodna Dalmacija** postoji **vrlo dobra povezanost** izbornih rezultata i broja građana novinara koji su komentirali kandidata. Na portalu **Dalmacija News** postoji **dobra povezanost** između izbornih rezultata i broja građana novinara koji su komentirali kandidata.

Dobiveni rezultati omogućavaju zaključak da postoji povezanost izbornih rezultata i participativnog novinarstva te **prihvaćanje hipoteze H1.**

3.8. Sažetak rezultata

Rezultati istraživanja pokazuju da postoje razlike između istraživanih portala s obzirom na:

a) broj članaka objavljenih o pojedinom kandidatu
b) broj komentara koji se odnose na pojedinog kandidata
c) broj građana novinara koji komentiraju pojedinog kandidata
d) centralne vrijednosti SO komentara o pojedinom kandidatu

e) centralne vrijednosti SO komentara o pojedinom kandidatu po različitim kategorijama
f) centralne vrijednosti SO komentara koji se odnose na građane novinare
g) naklonosti građana novinara prema pojedinom kandidatu, što je izraženo kroz udio pozitivno i negativno prema kandidatu orijentiranih građana novinara
h) naklonosti građana novinara jednih prema drugima, što je izraženo kroz udio pozitivno i negativno jednih prema drugima orijentiranih građana novinara

Unatoč razlikama uočavaju se i sličnosti između svih istraživanih portala s obzirom na:

a) izraženiji veći broj objavljenih članaka i komentara o Željku Kerumu te izraženiji veći broj građana novinara koji su komentirali tog kandidata u odnosu na druge kandidate
b) najlošije ocijenjenog kandidata u kategoriji Domoljublje (Ivo Baldasar)
c) najbolje ocijenjenog kandidata u kategoriji Izgled (Sanja Bilač)
d) pretežito negativne stavove građana novinara jednih prema drugima

Pomoću Spearmanovog testa korelacije ranga uočena je **povezanost između participativnog novinarstva i izbornih rezultata**, zbog čega se **prihvaća hipoteza H1**. Testiranje je izvršeno usporedbom broja glasova koji su kandidati dobili nakon prvoga izbornog kruga i vrijednosti sljedećih varijabli:

a) broja članaka objavljenih o kandidatu
b) broja komentara o pojedinom kandidatu
c) broja građana novinara koji su komentirali pojedinoga kandidata

Pomoću Spearmanovog testa korelacije ranga učena je **povezanost između broja građana novinara koji se pozitivno izjašnjavaju o kandidatu i izbornih rezultata**, zbog čega se **prihvaća hipoteza H2**. Uočena je i **povezanost između broja građana novinara koji se negativno izjašnjavaju o kandidatu i izbornih rezultata,** zbog čega se **prihvaća hipoteza H3.**

Na temelju izračuna centralnih vrijednosti SO komentara koji su se odnosili na kandidate za izbor splitskog gradonačelnika, postotka prema kandidatima pozitivno ili negativno orijentiranih građana novinara te na temelju prevladavajućeg broja riječi i izraza koji u izrađenom rječniku izražavaju negativne sentimente (77,32%), zaključeno je da su **motivi građana za participaciju pretežito negativni stavovi prema kandidatima**, zbog čega se **prihvaća hipoteza H4.**

Na temelju Kruskal-Wallis testa uspoređena je raspodjela rezultata dobivenih za vrijednosti ukupne SO komentara o građanima novinarima i kandidatima koje je na svim istraživanim portalima komentiralo barem 20 građana novinara. Test je pokazao da postoje statistički značajne razlike između raspodjele rezultata, zbog čega je zaključeno da građani novinari na istraživanim portalima nisu pripadali istoj populaciji birača. Zbog ovih rezultata **odbacuje se hipoteza H5** o postojanu sličnosti između komentara građana novinara na istraživanim portalima i usvaja alternativna – **ne postoji sličnost između komentara građana novinara na istraživanim portalima**. Odbacivanje hipoteze dodatno potkrepljuju rezultati dobiveni izračunom centralnih vrijednosti ukupne SO komentara i SO komentara po pojedinim kategorijama te udjelom prema kandidatima pozitivno i negativno orijentiranih građana novinara na istraživanim portalima, budući da se na svim istraživanim portalima uočavaju razlike s obzirom na spomenute vrijednosti.

Na svim je istraživanim portalima, s obzirom na razinu interaktivnosti, argumentiranosti i polemičnosti, uočena niska razina javne rasprave, s time da je najveća razina interaktivnosti i polemičnosti zabilježena na portalu 24 sata, a najveća razina argumentiranosti na portalu Slobodna Dalmacija. Također, na portalu Slobodna Dalmacija uočena je i najizraženija negativna prosječna SO komentara koji su se odnosili na sudionike konverzacije – građane novinare. Negativna prosječna SO komentara koji su se odnosili na građane novinare na novinskim portalima otkriva nam da građani novinari jedni prema drugima izražavaju pretežito negativne sentimente, što bi se moglo povezati i s čestom uporabom „ad hominem“ argumenata. Na temelju toga i rezultata dobivenih za centralne vrijednosti razine interaktivnosti, argumentiranosti i polemičnosti zaključuje se da je **konverzacija građana novinara na svim istraživanim portalima imala nisku razinu javne rasprave** te se **prihvaća hipoteza H6.**

4. Diskusija

4.1. Konverzacija građana novinara na novinskim portalima

Tragajući za idealom javne rasprave u političkoj javnoj sferi, onako kako ju je definirao Habermas (1991), kao oblik konverzacije u kojem su građani spremni saslušati tuđe dobre argumente i suočeni s njima promijeniti svoje mišljenje te u konačnici zajedno s ostalima doći do konsenzusa i odluka koje bi bile obvezujuća za sve, u ovom se istraživanju nastojalo utvrditi, na temelju studije više slučajeva novinskih portala, koliko je hrvatska internetska politička javna sfera u vrijeme prije lokalnih izbora 2013. bila uistinu prostor takve konverzacije, a koliko je u njoj dominirala konverzacija nabijena negativnim sentimentima u kojoj se sudionici više međusobno napadaju nego li racionalno sudjeluju u konverzaciji. Naime, kada nemaju dobrih argumenata koji se definiraju kao niz tvrdnji od kojih je jedna zaključak, a druge premise koje bi morale biti provjerljive informacije ili opće prihvaćena načela (Gensler, 2012; Stromer – Galley, 2007; Jansen, 2014; Weger&Aaakhus, 2003; Govier, 2013), građani napadaju jedni druge, a takvi se napadi tad nazivaju lažnima ili „ad hominem“ argumentima (Kišiček, 2013). Zastupljenost uvreda i izraza kojima se sudionika konverzacije pokušava omalovažiti jedan je od pokazatelja konverzacije koja nema odlike javne rasprave ili se za nju može reći da ima nisku razinu javne rasprave. Zastupljenost i karakteristike uvreda i omalovažavanja u konverzaciji građana na internetu predmet su brojnih istraživanja znanstvenika (Erjavec & Poler-Kovačič, 2013; Jensen, 2014), a u većini slučajeva pokazalo se da je udio komentara ili objava građana novinara s takvim sadržajem velik (Richardson & Stanyer, 2011; Park & Cardie, 2014), premda se razlikuje od mrežnog mjesta do mrežnog mjesta i varira između 2,38 % i 42, 64% (Ruiz et al., 2011). U ovom je istraživanju pokazatelj zastupljenosti takvih sadržaja prosječna SO komentara u kojima su izraženi sentimenti prema sudionicima konverzacije – građanima novinarima na novinskim portalima. Kao i u drugim istraživanjima uočeno je da se izraženost negativnih sentimenata koje građani novinari izražavaju jedni prema drugima razlikuje od portala do portala. Na svim je portalima u ovom istraživanju prosječna SO komentara građana novinara koji su se odnosili na druge građane novinare negativna, s tim da je negativna prosječna vrijednost bila najviše izražena na novinskom portalu Slobodna Dalmacija (-10), a najmanje na novinskom portalu (-0,513). U istraživanju je odbačena hipoteza da su komentari građana novinara na istraživanim portalima slični budući da je usporedbom raspodjele rezultata za SO komentara koji su se odnosili na građane novinare uočeno da postoje

statistički značajne razlike u raspodjeli rezultata, pa s obzirom na varijablu SO komentara koja je mjerila sentimente izražene prema sudionicima konverzacije možemo kazati da građani novinari na različitim portalima ne pripadaju istoj populaciji. Ako bismo negativnu SO komentara koji se odnose na sudionike konverzacije povezali sa zastupljenošću „ad hominem" argumenata i s tim u vezi s niskom razinom javne rasprave, mogli bismo kazati da se zajednice građana novinara okupljene oko novinskih portala razlikuju prema kvaliteti konverzacije čiji je pokazatelj poštovanje koje građani novinari iskazuju jedni prema drugima tijekom konverzacije. No, postojanje „ad hominem" argumenata ne mora nužno negativno utjecati na razinu javne rasprave, jer građane novinare takva vrsta konverzacije može ponukati da se više trude oko obrane svoga stava uporabom dobrih argumenata (Weger & Aaakhus, 2003; Papacharissi, 2004). S tim u vezi, u slučaju istraživanih hrvatskih novinskih portala može se primijetiti da je upravo na novinskom portalu Slobodna Dalmacija, na kojem je najizraženija negativna prosječna SO komentara koji su se odnosili na sudionike konverzacije (-10), ujedno i najveći udio argumentiranih komentara (15, 40%). Zanimljivo je da je na portalu 24 sata, na kojem je negativna prosječna SO komentara koji su se odnosili na građane novinare bila najmanje izražena (-0,513), bila i jedna od dvije najniže razine argumentiranosti (5, 69%).

Osim dobre argumentiranosti javna rasprava pretpostavlja i visoku interaktivnost (Graham, 2008; Stromer – Galley, 2007; Rafaelli, 1988) sudionika konverzacije, što je međusobno povezano, jer razmjena argumenata u konverzaciji pretpostavlja da sudionici stupaju u interakciju jedni s drugima, tako da interaktivnost konverzacije predstavlja strukturalni pokazatelj argumentiranosti (Gonzales – Bailon et al., 2010). Naime, struktura konverzacije na internetu izgleda poput radijalnog stabla i u njoj se mogu uočiti slojevi konverzacije, gdje su u prvom sloju odgovori na početnu objavu ili novinski članaka, u drugom su odgovori na objave ili komentare iz prvog sloja i tako redom. Konverzacija u dubljim slojevima stvara pretpostavke za veću dobru argumentiranost. Međutim, radi se samo o pretpostavci, budući da konverzacija može biti duboka, ali do dubljih slojeva konverzacije može se doći i razmjenom uvreda i „ad hominem" argumenata, što je tijekom analize komentara primijećeno i u ovom istraživanju. Nadalje, odlika je javne rasprave da uključuje što veći broj sudionika i s tim u vezi da se u njoj u iznosi što veći broj drugačijih stavova, čime se izbjegava njezina centralizacija u kojoj ima malo izraženih stavova i u kojoj dominira mali broj građana (Graham, 2008; Milioni et al., 2012; Collins & Nerlich, 2015), kao i pojava da se na mrežnim mjestima stvaraju ekstremizmi enklava (Sunstein, 2007). Duboka konverzacija može se postići i kada u njoj sudjeluje mali broj građana novinara, pa su Gomez et al. (2008) zaključili da dubina konverzacije, koja predstavlja najveći redni broj njenog sloja, nije dovoljno dobar

strukturalni pokazatelj kvalitete konverzacije. Stoga su definirali varijablu razine polemičnosti koja uzima u obzir i broj građana novinara u određenom sloju, kao i ukupan broj komentara ili objava u nekoj konverzaciji. Razina polemičnosti konverzacije stoga je veća što je više sudionika konverzacije u sloju u odnosu na ukupni broj komentara u konverzaciji. Računajući razinu polemičnosti na forumu Slashdot oni su uočili da se ta varijabla razlikuje od teme do teme o kojoj su građani novinari stupali u konverzaciju. Najveća razina polemičnosti u njihovom je istraživanju iznosila 11, što je značilo da je u toj konverzaciji postojao jedanaesti sloj u kojem je bilo barem jedanaest sudionika (h – indeks konverzacije). Ako taj rezultat usporedimo s najvećom vrijednošću razine polemičnosti na novinskim portalima obuhvaćenim ovim istraživanjem, a to je razina polemičnosti od 8,01 na portalu Indeks koja se odnosila na konverzaciju o ustupanju gradskog stadiona za koncert Thompsonu, možemo kazati da su i na hrvatskim novinskim portalima neke konverzacije bile vrlo polemične. Međutim, radi se o manjem broju konverzacija, budući da su medijani razine polemičnosti na svim portalima bili znatno niži i varirali su između najnižeg 2,000 (Dalmacija News) i najvišeg 3,016 (24 sata), što je značajno niže od maksimalnih vrijednosti. Na svim su nacionalnim novinskim portalima medijani razine polemičnosti bili nešto viši (između 2,023 i 3,016), dok su na lokalnim bili niži (između 2,000 i 2,029), što se može pripisati i činjenici da nacionalni novinski portali imaju veći broj posjetitelja i s tim u vezi veći broj građana novinara sudjeluje u konverzacijama, pa je lakše postići i dublje slojeve konverzacije. Ovdje treba istaknuti da se razina polemičnosti može razlikovati od konverzacije do konverzacije zbog niza čimbenika, a jedan od njih je i sama tema konverzacije. Naime, na svim su portalima u ovom istraživanju uočene teme koje izazivaju veću polemičnost, a one se mahom odnose na postavljanje križa, gradnju spomenika Tuđmanu, ustupanje stadiona Thompsonu, pjevanje ustaških pjesama i slično. Na temelju toga može se pretpostaviti da se na svim istraživanim portalima teme koje izazivaju veću polemičnost odnose na vjerska pitanja te na prvog hrvatskog predsjednika i općenito hrvatsku državu.

Osim razine polemičnosti, kao strukturalni pokazatelja kvalitete konverzacije može se upotrijebiti i ukupan broj komentara ili objava koje ne pripadaju prvom sloju nego svim ostalim slojevima konverzacije (Graham, 2008; Jensen, 2014), što znači da predstavljaju odgovore na već napisane komentare i objave građana. Istraživanja interaktivnosti konverzacije na novinskim portalima u europskim državama i SAD-u (Richardson & Stanyer, 2011; Collins & Nerlich, 2015; Gode et al., 2016; Manosevitch & Walker, 2009) pokazala su da udio objava ili komentara koji predstavljaju odgovore značajno varira od 3 % do 70 %, u ovisnosti od portala do portala. U ovom istraživanju prosječna najveća razina interaktivnosti (postotak komentara koji predstavljaju odgovore na već postavljene komentare građana novinara) imao je novinski

portal 24 sata (41, 19 %), a najmanju novinski portali Slobodna Dalmacija (21, 05%) i Dalmacija News (20, 59%). I ovdje se niža razina interaktivnosti na lokalnim novinskim portalima može povezati s činjenicom da ih posjećuje manji broj građana.

Sama razina interaktivnosti ne može nam mnogo reći o kvaliteti konverzacije, budući da za nju može biti odgovoran mali broj sudionika, ali kad se kombinira s razinom polemičnosti i, što je još važnije, razinom argumentiranosti (postotkom argumentiranih komentara), možemo dobiti jasniju sliku o konverzaciji građana na novinskim portalima. Ako se usporede rezultati u drugim zemljama (Ruiz et al., 2011; Manosewitch & Walker, 2009; Jensen, 2014) u kojima zastupljenost argumentiranih komentara varira između 11, 95% i 78,9%, možemo kazati da je na istraživanim hrvatskim novinskim portalima razina interaktivnosti vrlo niska. Naime, na svim nacionalnim novinskim portalima ona je iznosila između 5, 69 % i 7,33%, dok je nešto veća na lokalnom novinskom portalu Dalmacija News (9,15%) i najveća na novinskom portalu Slobodna Dalmacija (15, 40%). Ovdje se može pretpostaviti da je to povezano s činjenicom da su se konverzacije vodile o lokalnim izborima i da građani novinari koji koriste lokalne novinske portale pripadaju lokalnoj zajednici te su više zainteresirani za tu temu, pa se s tim u vezi i više angažiraju u obrani svojih stavova.

Ako se rezultati dobiveni za varijable koje su mjerile interaktivnost, polemičnost, argumentiranost i sentimente koje građani novinari izražavaju jedni prema drugima usporede s modelom konverzacija na internetu kakve je predložio Freelon (2010), mogli bismo kazati da je na svim istraživanim novinskim portalima zastupljen liberalno individualistički model za koji je tipična niska interaktivnost i svadljivost sudionika konverzacije, a odgovor na pitanje kakvom medijskom sustavu pripadaju istraživani hrvatski novinski portali teško je dati. Naime, Ruiz et. Al (2011) su uočili da se veliki novinski portali u Francuskoj, Španjolskoj i Italiji razlikuju od onih u SAD-u i Velikoj Britaniji s obzirom na kvalitetu konverzacije građana novinara koji pišu komentare na novinske članke. U prvoj skupini manje je bila izražena polarizacija mnijenja, manja zastupljenost uvredljivih komentara (manje od 3 % na britanskom novinskom portalu Quardian), a razina argumentiranosti komentara iznosila je između 65,6% i 78,9%. U drugoj je skupini bila izražena polarizacija mnijenja, bilo je više uvredljivih komentara (42, 64% na francuskom portalu LeMonde), a razina je argumentiranosti komentara bila između 42, 5% i 58, 1%. Drugu su skupinu portala smjestili u Polarizirano pluralni medijski sustav koji je tipičan za mediteranske zemlje (Hallin & Mancini, 2004, p. 90) i odlikuje ga najniža kvaliteta konverzacije s obzirom na Habermasovu definiciju javne rasprave, a drugu su skupinu portala smjestili u Liberalni model koji ima kvalitetnije odlike konverzacije i tipičan je za SAD i Veliku Britaniju - zemlje koje imaju dužu tradiciju demokracije i slobode tiska

(Hallin & Mancini, 2004, p. 11). Budući da je na istraživanim hrvatskim novinskim portalima izmjerena znatno niža razina argumentiranosti od one koja je uočena na francuskim, talijanskim i španjolskim portalima vodećih novinskih kuća, možda bi se moglo reći da istraživani hrvatski novinski portali predstavljaju izrazito Polarizirano-pluralizirani medijski sustav.

4.2. Sentimenti izraženi prema kandidatima

Pišući komentare i objave građani novinari u internetsku političku javnu sferu unose informacije i izražavaju sentimente o različitim političkim temama i političarima, kao što to rade i profesionalni novinari, a sadržaji koje objavljuju dostupni su svima koji se koriste internetom. Na forumima građani novinari mogu posve samostalno birati teme uz koje izražavaju stavove obojane emocijama koje nazivamo sentimentima (Boiy et al., 2007, p. 350), a kada pišu komentare na novinskim portalima odabir entiteta prema kojem izražavaju sentimente uvjetovan je temama koje u novinskim člancima odabiru profesionalni novinari, pa se takav oblik novinarstva ostvaruje kroz suradnju s profesionalnim novinarima i naziva participativnim novinarstvom (Henig, 2005; Nip, 2006, Friedland & Kim, 2009). Komentari koji su objavljeni uz novinske članke dostupni su čitateljima jednako kao i sam novinski članak, a analiza sadržaja takvih komentara može otkriti sentimente građana novinara i poslužiti za dubinsko istraživanje javnog mnijenja koje se može definirati kao "mnijenja privatnih osoba za koje vlada smatra da ih je razborito uvažiti" (Key, 1961, navedeno u Zaller, 2003: 2) te na temelju toga i za određivanje političkog profila posjetitelja novinskih portala (Meguebli et al., 2014). Samo je mnijenje širok pojam koji uključuje sentimente, enitete i aspekte entiteta prema kojima se sentimenti izražavaju, a entiteti mogu biti osobe, proizvodi, događaji, pojave i sl. (Liu, 2012). U ovom su istraživanju, osim građana novinara kao sudionika konverzacije, entitete predstavljali i političari - kandidati za izbor splitskog gradonačelnika 2013. Tijekom analize sentimenata pomoću određivanja SO komentara uočeni su i aspekti entiteta (odlike kandidata) prema kojima su građani novinari također izražavali sentimente. Kao i u drugim istraživanjima (Tumitan i Becker, 2013; Carvalho etal., 2011) uočeno je da upravo prema političkim temama i samim političarima građani novinari na internetu izražavaju pretežito negativne sentimente i da upravo takvi entiteti izazivaju kod njih najviše negativnih komentara (Abdulla et al., 2014), što znači da im novinski portali, forumi i blogovi najčešće služe za iskazivanje političkih frustracija, premda postoje i mrežna mjesta na kojima dominiraju pozitivni komentari (Jensen, 2014). Analiza sentimenata u komentarima koji se odnose na

političare i političke teme ukazuje i na različite populacije posjetitelja novinskih portala koji pišu komentare, jer isti političar ili ista politička tema na različitim novinskim portalima ne dobiva jednak udio pozitivnih i negativnih komentara (Balasubramanyan et al., 2012). I u ovom je istraživanju potvrđeno da različiti novinski portali okupljaju različite populacije građana novinara. Hipoteza o sličnosti komentara na svim istraživanim portalima odbačena je na temelju usporedbe raspodjele rezultata za SO komentara o građanima novinarima i o kandidatima koji su u dovoljnom broju bili zastupljeni na svim istraživanim portalima. I opisna je statistika pokazala razlike u izražavanju sentimenata prema pojedinim političarima na različitim portalima. Tako je za Željka Keruma najveći udio građana koji su ga pozitivno komentirali bio na novinskom portalu Dalmacija News (27%), a najmanji na portalu Index (14%). Ivo Baldasar najveći je udio prema njemu pozitivno orijentiranih građana novinara imao na portalu Indeks (19%), a najmanje na portalu 24 sata (2,74%). Anđelku Visković najveći je udio građana pozitivno komentirao na portalu Indeks (29%), a najmanje na T-portalu (4%). O Vjekoslavu Ivaniševiću najviše je pozitivno orijentiranih građana novinara bilo na portalu Dalmacija News (23%), a najmanje na portalu Indeks (7%). I kod ostalih se kandidata primjećuju razlike od portala do portala s obzirom na udio prema njima pozitivno i negativno orijentiranih građana novinara, no za sve je kandidate na istraživanim portalima tipična dominacija prema njima negativno orijentiranih građana novinara. Jedini izuzetak predstavlja Marijana Puljak koja je na portalima 24 sata i Slobodna Dalmacija imala pozitivne prosječne vrijednosti SO komentara. Na portalu Slobodna Dalmacija većina se građana novinara o njoj pozitivno izjasnila (58%), a prosječna SO komentara bila je 2,89. Na svim je portalima na kojima je bila komentirana imala najveći udio prema njoj pozitivno orijentiranih građana novinara. Također, građani su novinari izražavali uglavnom pozitivne sentimente prema njenim odlikama SP (sposobnost) , MO (moralnost), PR (pristojnost), OD (odgovornost) i gotovo svugdje je imala pozitivnu prosječnu SO komentara u kategoriji PO (potpora). Iako nije ušla u drugi krug izbora za splitskog gradonačelnika njezina je lista za gradsko vijeće polučila uspjeh i ona je sama postala gradska vijećnica. Tome bi mogao biti uzrok činjenica da je ona tijekom predizborne kampanje bila neovisni kandidat i usto je bila dotad politički uglavnom nepoznata. Međutim, i kandidat Damir Vidošević nije pripadao nijednoj stranci i dotada je bio politički nepoznat, ali nije polučio takav rezultat. U njegovom slučaju možda je za lošiji rezultat, u odnosu na Marijanu Puljak, pridonijela činjenica da je on bio kandidat političke grupacije koju je predvodio javnosti poznat saborski zastupnik Ivan Grubišić. I Tomislav Zaninović bio je neovisni kandidat, ali nije polučio uspjeh na izborima niti izazvao pozitivnije sentimente građana novinara na istraživanim portalima. Međutim, uz njega se vezala činjenica da je u prošlosti bio članom nekoliko

političkih stranaka. Što je uzrok uspjehu Marijane Puljak i uočljivo pozitivnijim sentimentima koje su prema njoj izražavali građani novinari moglo bi se istraživati u zasebnoj studiji slučaja.

U ovom je istraživanju tijekom analize sentimenata prema odlikama kandidata uočeno kako su građani novinari kandidata SDP-a Ivu Baldasaru najlošije ocijenili u kategoriji DO (domoljublje), jer je na svim istraživanim portalima u toj kategoriji imao najnižu prosječnu SO komentara, a kandidata HDZ-a Vjekoslava Ivaniševića u kategoriji KR (kriminalnost), jer je u četiri od pet istraživanih portala u toj kategoriji imao najnižu prosječnu SO komentara. Budući da su komentari građana novinara na svim istraživanim portalima bili slabo argumentirani, može se pretpostaviti da građani novinari imaju mahom predrasude o kandidatima velikih stranaka, pa se tako kandidati HDZ-a povezuju s kriminalnošću, a kandidati SDP-a s manjkom domoljublja. Bilo bi zanimljivo u posebnoj studiji analizirati vrste obrazloženja stavova građana novinara o kandidatima spomenutih stranaka.

Željko Kerum kao najkomentiraniji kandidat na svim je istraživanim portalima izazvao kod pojedinih građana novinara izrazito negativne sentimente. Na portalu Slobodna Dalmacija prosječna SO komentara (-10,36) o njemu bila je značajno niža od medijana (-2), a najniža ukupna SO komentara jednog građanina novinara o njemu iznosila je -432, što znači da je taj građanin novinar na portalu Slobodna Dalmacija za njega upotrijebio 432 riječi i izraza koji izražavaju negativne sentimente. Izrazito negativnu prosječnu SO komentara na tom je portalu imao i Vjekoslav Ivanišević (-8,54), a za njega je najniža vrijednost ukupnih SO komentara jednog građanina novinara iznosila -260. Također, izrazito niske vrijednosti SO komentara primijećene su i za Ivu Baldasara (-212) i Anđelku Visković (-198). S obzirom da je prosječna SO komentara koji su se odnosili na sudionike konverzacija na ovom portalu također bila najniža u odnosu na ostale portale (-10), može se zaključiti da su na portalu Slobodna Dalmacija građani novinari izražavali jake sentimente prema političarima i drugim građanima novinarima, više nego na drugim portalima.

Analiza je sentimenata na istraživanim portalima pokazala da među njima postoje razlike s obzirom na jakost izraženih sentimenata i sklonosti građana novinara prema pojedinim kandidatima. Nadalje, za većinu je kandidata na portalima uočen nerazmjer između udjela prema kandidatima pozitivno i negativno orijentiranih građana te dominacija prema svim kandidatima negativno orijentiranih građana novinara. Moglo bi se reći da se na istraživanim novinskim portalima uočila polarizacija negativnog mnijenja prema kandidatima, da se jakost izraženih sentimenata razlikuje od portala do portala i da je najveća na portalu Slobodna Dalmacija, a kao što su Ruiz et al. (2011, p. 484) primijetili da kulturalni kontekst kojem različiti novinski portali pripadaju utječe na kvalitetu konverzacije, moglo bi se i na temelju

ovog istraživanja zaključiti da jakost izraženih sentimenta na pojedinom portalu ovisi i o kulturalnom kontekstu kojem pripadaju građani novinari na različitim portalima.

4.3. Povezanost participativnog novinarstva i izbornih rezultata

Objavom novinskih članaka o kandidatima i načinom na koji pišu o njima profesionalni novinari ostvaruju posredničku ulogu u komunikaciji između periferije i centra političkog sustava (Habermas, 2006), što se očituje i u participativnom novinarstvu na mreži. Građani novinari na novinskim portalima reagiraju na objavljene članke i pišu komentare, zbog čega se njihova aktivnost ne može smatrati posve samostalnom, već je povezana s aktivnošću profesionalnih novinara (Henig, 2005; Nip, 2006, Friedland & Kim, 2009). U komentarima građani novinari izražavaju svoja mnijenja kao privatne osobe (Key, 1961, navedeno u Zaller, 2003: 2), kao što to rade i na demokratskim izborima kada biraju političare koji nakon toga postaju izvršitelji javnih vlasti. Cilj je ovog istraživanja bio opisati odlike participativnog novinarstva na istraživanim novinskim portalima koje se očituje kroz nekoliko varijabli te utvrditi postoji li povezanost između odlika participativnog novinarstva na istraživanim novinskim portalima i javnog mnijenja izraženog na lokalnim izborima za splitskog gradonačelnika 2013. Budući da jednu od odlika participativnog novinarstva predstavlja i mnijenje građana novinara koje oni očituju kroz neprofesionalne aktivnosti, možemo kazati da se u ovom istraživanju utvrđivala povezanost između javnog mnijenja građana novinara na istraživanim novinskim portalima i javnog mnijenja građana izraženog na lokalnim izborima za splitskog gradonačelnika 2013. U istraživanju su određene varijable čije vrijednosti opisuju odlike participativnog novinarstva. Uočeno je nekoliko varijabli na čiju vrijednost izravno utječu građani novinari: jakost i predznak izraženih sentimenata građana novinara o pojedinom entitetu, broj komentara u kojima se ti sentimenti izražavaju, broj građana novinara koji izražavaju sentimente, kao i odlike konverzacije građana novinara koja se ostvaruje uz objavljene članke. No, postoje još dvije varijable na čiju vrijednost ne utječu izravno građani novinari: brojnost novinskih članaka o entitetima prema kojima se izražavaju sentimenti i sentimenti profesionalnih novinara izraženi prema entitetima u objavljenim člancima. Ove su dvije varijable u slučaju participativnog novinarstva zapravo početne varijable za koje je razumno pretpostaviti da snažno utječu na sve ostale. Naime, sadržaji članaka i sentimenti koje profesionalni novinari izražavaju u njima utječu na izražavanje sentimenata i odlike konverzacije građana novinara koja se razvija uz pojedini članak, budući da u predodžbi

konverzacije građana novinara na internetu pomoću radijalnog stabla (Gomez et al., 2008) na primjeru novinskih portala u središtu uočavamo objavljeni novinski članaka, dok komentari predstavljaju reakcije na sadržaj članaka. Možemo reći da konverzaciju na novinskim portalima predstavlja razmjena sentimenata koja se odvija između profesionalnih novinara i građana novinara, najčešće u prvom sloju konverzacije te između samih građana novinara u dubljim slojevima konverzacije. Istraživanja (Balasubramanyan, 2012) pokazuju da je tema objavljenog novinskog članka uistinu jedna od početnih varijabli koja utječe na ostale, budući da je uočeno postojanje tema koje izazivaju visoku polemičnost i veliki broj komentara, pa s tim u vezi i veliku količinu izraženih sentimenata. Tako su u ovom istraživanju visoku razinu polemičnosti izazvali novinski članci o podizanju spomenika prvom hrvatskom predsjedniku, gradnji križa na Marjanu, ustupanju gradskog stadiona za koncert Thompsonu, doniraju splitskih redovnica, pjevanju ustaških pjesama i sl., pa možemo zaključiti da su građani novinari na svim istraživanim portalima intenzivno reagirali na teme koje se povezuju s vjerom, domoljubljem, odnosom prema Crkvi i hrvatskoj državi. Nadalje, početna varijabla na koju su izravno utjecali profesionalni novinari odnosila se na broj objavljenih članaka o pojedinom kandidatu. Sasvim je očekivano da je o kandidatima o kojima je objavljeno više članaka bilo više komentara i više građana novinara koji su ih komentirali. Ono što se u ovom istraživanju uočilo je nerazmjeran odnos između broja članaka objavljenih o Željku Kerumu i svim ostalim kandidatima, što je za posljedicu imalo i nerazmjeran odnos broja komentara i broja građana koji su komentirali Željka Keruma u odnosu na ostale kandidate. Tako je na nacionalnim novinskim portalima 24 sata i Indeks oko 80 % članaka bilo o Kerumu, na T-portalu bilo ih je nešto manje (57,14%), a na lokalnim je novinskim portalima nerazmjer bio manji – na novinskom portalu Slobodna Dalmacija 61,18 % komentara bilo je o Željku Kerumu, a na Dalmacija News 32 %. Uočava se da je na najmanjem novinskom portalu Dalmacija News bila najmanje izražena dominacija članaka o Željku Kerumu. Zapravo, u ovom se istraživanju moglo uočiti da što je novinski portal imao manji broj mjesečnih posjetitelja, to je na njemu bila manje izražena dominacija članaka o Željku Kerumu. U odnosu na ostale kandidate primijećena je razlika od portala do portala s obzirom na udio članaka objavljenih o njima, a o nekim kandidatima (Marijo Popović i Pero Vučica) sva tri nacionalna novinska portala uopće nisu objavljivali članke. Zanimljivo je da je o Sanji Bilač postotak članaka na istraživanim portalima varirao od 3,49 % do 5,88%, a na T-portalu je iznosio 17,86%.

Testiranje povezanosti između varijabli participativnog novinarstva i izbornih rezultata provelo se na lokalnim portalima, budući da su samo na njima bili objavljeni članci o svim

kandidatima. Tako je na oba portala uočena vrlo dobra povezanost između broja objavljenih članaka o kandidatima i izbornih rezultata, s tim da je na portalu Dalmacija News ona bila nešto veća (r=0,84) nego li na portalu Slobodna Dalmacija (0,75). Pri tom je primijenjen Spearmanov test korelacije ranga, a izborni su rezultati predstavljeni brojem glasova koje su kandidati dobili nakon prvog izbornog kruga. Ako izuzmemo Željka Keruma o kojem je na svim portalima napisano najviše članaka, uočava se da je na portalu Dalmacija News najviše članaka bilo o Vjekoslavu Ivaniševiću (20%) i o Ivi Baldasaru (13%), dvojici kandidata koji su imali najviše glasova nakon prvog izbornog kruga. Kada je riječ o povezanosti broja komentara o pojedinom kandidatu i izbornih rezultata vrlo dobra je povezanost uočena na portalu Slobodna Dalmacija (r=0,85), a dobra je povezanost uočena na portalu Dalmacija News (r=0,64). I ovdje, ako izuzmemo Željka Keruma o kojem je na svim istraživanim portalima napisano najviše komentara, uočavamo da je na portalu Slobodna Dalmacija najviše komentara bilo o Vjekoslavu Ivaniševiću (14,33%), a zatim o Ivi Baldasaru (8,78%). Sličan se rezultat za povezanost dobio uspoređujući broj građana novinara koji su komentirali kandidata i izborne rezultate. I ovdje je na portalu Slobodna Dalmacija utvrđena vrlo dobra povezanost, a na portalu Dalmacija News dobra povezanost. Ako izuzmemo iz rangiranja Željka Keruma kojeg je na svim istraživanim portalima komentirao najveći broj građana, uočavamo da je na portalu Slobodna Dalmacija najviše građana novinara komentiralo Vjekoslava Ivaniševića (14,33%), a zatim Ivu Baldasara (24,96%). Činjenica da je Željko Kerum bio tada aktualni gradonačelnik Splita zasigurno je pridonijela dominantnoj zastupljenosti broja objavljenih članaka o njemu na svim istraživanim portalima i s tim u vezi velikom broju građana novinara koji su ga komentirali, budući da se o njemu često pisalo tijekom četverogodišnjeg mandata i bio je u javnosti poznat po kontroverznom ponašanju. Zanimljivo je da je na dva lokalna portala, koja su poslužila za utvrđivanje povezanosti varijabli participativnog novinarstva, nakon Željka Keruma najviše komentara imao Vjekoslav Ivanišević koji je nakon prvog izbornog kruga bio drugoplasirani. Razvidno je da niz čimbenika utječe na formiranje političkih stavova građana i da su oni rezultat interpretacije novih informacija kroz leće prijašnjih pretpostavki i uvjerenja (McCombs, 1997) te da varijable participativnog novinarstva – broj objavljenih članaka o kandidatu, broj komentara o njemu i broj građana novinara koji ga komentiraju ne mogu biti jedini pokazatelji javnog mnijenja, nego tek jedni od mnogih. I u samoj statistici uočavanje povezanosti među varijablama ne znači da one sigurno izravno utječu jedna na drugu, već da postoji mogućnost takvog utjecaja koju bi trebalo ispitati u eksperimentalnim uvjetima (Petz, 2004). Treba uzeti u obzir da se ovdje radi o posebnoj vrsti studije slučaja – studiji više slučajeva, pa s tim se u vezi rezultati ne mogu generalizirati na sve novinske portale.

Prije utvrđivanja povezanosti izbornih rezultata i izraženih sentimenata građana novinara na portalima Slobodna Dalmacija i Dalmacija News, za svakog se građanina novinara na temelju ukupne SO svih njegovih komentara na tom portalu utvrdilo je li on pozitivno ili negativno orijentiran prema kandidatu. Na taj se način za svakog kandidata dobio broj građana novinara koji su prema njemu pozitivno ili negativno bili orijentirani. Spearmanov koeficijent korelacije ranga pokazao je da je na portalu Slobodna Dalmacija postojala vrlo dobra povezanost između broja građana novinara koji su negativno komentirali kandidata i izbornih rezultata (0,79), dok je povezanost izbornih rezultata i broja prema kandidatu pozitivno orijentiranih građana novinara bila nešto manja (0,66). Na portalu Dalmacija News utvrđena je dobra i slična povezanost između pozitivno i negativno orijentiranih birača i izbornih rezultata. To je slično rezultatu Carvalha et al. (2011, p. 567) koji su tijekom izbora za portugalski parlament uočili da je najviše glasova na izborima dobio kandidat o kojemu je na portalu Publico napisano najviše negativnih komentara te da postoji slična i velika povezanost između broja pozitivnih komentara i izbornih rezultata, kao i između broja negativnih komentara i izbornih rezultata. Tumitan i Becker (2013) su analizirajući rečenice na brazilskom novinskom portalu Folha de São Paulo uočili da postoji povezanost između udjela pozitivnih i negativnih rečenica o kandidatu i rezultata predizbornih anketa. Naime, kada bi se udio pozitivnih rečenica povećavao a smanjivao broj negativnih rečenica, povećao bi se i broj birača koji su mu bili skloni u predizbornim anketama. U ovom je istraživanju pak utvrđeno, slično kao i kod Carvalha et al. (2011), da pri utvrđivanju povezanosti sentimenata i izbornih rezultata nije bitan toliko predznak sentimenata građana novinara koliko njegova jakost i količina komentara u kojima su izraženi. U svakom slučaju, može se zaključiti da je participativno novinasrtvo, čije su odlike mjerene različitim varijablama, povezano s izbornim rezultatima.

4.4. Ograničenja istraživanja

Budući da je ovo istraživanje oblik studije slučaja rezultati se ne mogu generalizirati na sve novinske portale. Uostalom, i dosadašnja su istraživanja pokazala da se populacija građana novinara razlikuje od portala do portala i da kulturalni kontekst utječe na odlike konverzacije građana novinara i na jakost sentimenata koje izražavaju jedni prema drugima ili prema entitetima koje komentiraju (Ruiz et al, 2011; Godde et al, 2016). Nadalje, veličine uzorka komentara razlikovale su od portala do portala, ali budući da je odabrano dovoljno dugo razdoblje, od siječnja do svibnja 2013., za sve je portale cjelokupna količina komentara bila

dovoljno velika. Međutim, količina se komentara o pojedinim kandidatima bitno razlikovala i na samim portalima, a za neke kandidate uopće nije bilo dovoljnog broja komentara i građana novinara koji su ih komentirali da bi se dobiveni rezultati mogli smatrati statistički važnima, što je i istaknuto u poglavlju o rezultatima istraživanja. Slabo komentirani kandidati o kojima uopće nije bilo objavljenih članaka (sva tri nacionalna portala) ili ih je bilo vrlo malo, bili su Marijo Popović i Pero Vučica. Za ostale kandidate broj komentara građana novinara varirao je od portala do portala, ali može se reći da je taj broj, s obzirom na potrebe statističke analize, na svim istraživanim portalima bio uglavnom zadovoljavajući za kandidate: Sanju Bilač, Željka Keruma i Ivu Baldasara, koje je komentiralo barem 20 građana novinara. Stoga se usporedba raspodjela rezultata SO komentara izvršila samo za ove kandidate i na temelju toga je zaključeno da se populacija građana novinara na istraživanim portalima razlikuje. Za ispravan zaključak o različitim populacijama građana novinara na različitim novinskim portalima dovoljno je bilo uzeti nekoliko kandidata i to ograničenje nije predstavljalo problem, ali poteškoće su nastale pri uspoređivanju prosječnih vrijednosti SO komentara u različitim kategorijama, jer je za neke kandidate bilo premalo komentara da bi prosječna vrijednost imala nekakvu statističku važnost i da bi se mogla uspoređivati s prosječnim vrijednostima SO komentara o drugim kandidatima. Stoga grafovi koji prikazuju odnos prosječnih SO komentara u različitim kategorijama za kandidate s malim brojem komentara nisu dovoljno pouzdani.

Nadalje, u ovom je istraživanju pretpostavljeno da je na svakom novinskom portalu jedinstvena skupina građana novinara i da je jedan građanin novinar aktivan na samo jednom portalu, što ne mora biti točno budući da su građani novinari uglavnom anonimni i mogu pisati pod različitim ili čak pod istim imenima na različitim portalima. Kako se u istraživanju proveo Kruskal-Walis test za koji se traži da u uspoređivanim skupinama budu različiti ispitanici, ovdje bi se da je testiranjem utvrđena sličnost raspodjele rezultata mogao dovesti u pitanje rezultat tog testa. Međutim, kako je utvrđena različitost i kako niz drugih rezultata koji se odnose na centralne vrijednosti SO komentara upućuju na zaključak o različitosti, činjenica da je jedan te isti građanin novinar mogao pisati komentare na različitim portalima ne bi trebala zabrinjavati i dovoditi u pitanje zaključak o postojanju različitih populacija građana novinara na različitim novinskim portalima. Kudikamo veći problem predstavlja činjenica da jedan te isti građanin novinar može pisati pod različitim nazivima na istom portalu, tako da je točan broj građanina novinara koji komentiraju kandidata nešto upitniji. S tim u vezi moguće je da nije posve točan ni broj prema kandidatu pozitivno ili negativno orijentiranih građana novinara. Također, treba uzeti u obzir i činjenicu da su neki komentari prije arhiviranja za potrebe ovog istraživanja bili izbrisani, ili od moderatora novinskih portala zbog uvredljivog sadržaja, ili od samih građana

novinara, tako da se ne može tvrditi kako su uzorku bili baš svi komentari napisani o kandidatima. Međutim, kako je riječ o velikom uzorku nedostatak nekih komentara nije mogao bitno utjecati na rezultat.

Nadalje, treba upozoriti da građani novinari koji su komentirali kandidate za izbor splitskog gradonačelnika nisu uopće morali biti građani Splita, što su neki izrijekom i navodili u svojim komentarima. Zato se istraživanje povezanosti varijabli participativnog novinarstva na istraživanim portalima i izbornih rezultata ne smije shvatiti kao istraživanje kojemu je cilj otkriti odražavaju li građani novinari na istraživanim portalima javno mnijenje splitskih birača. Za takvo bi istraživanje trebalo u analizu uključiti samo građane novinare koji pripadaju populaciji birača na području Splita i tada bi se, možemo pretpostaviti, mogla utvrditi i veća povezanost između istraživanih varijabli i izbornih rezultata.

Metodološki, ostaje otvorenim pitanje pouzdanosti određivanja SO komentara s latentnim sadržajem, poput ironije, ali taj nedostatak umanjuje činjenica da je u analizi obuhvaćen veliki broj komentara, pa i u slučaju pogrešne procjene, u tako velikom uzorku to ne bi trebalo značajno utjecati na rezultat. I tu veći problem predstavlja točno utvrđivanje SO komentara koji se odnose na slabo komentirane kandidate, pa je zato važno naglasiti da u ovom istraživanju najveću pouzdanost imaju rezultati dobiveni za kandidate koji su češće bili komentirani poput Željka Keruma, Ive Baldasara, Vjekoslava Ivaniševića i Anđelke Visković. Nadalje, u nekim je komentarima teže bilo odrediti kojoj kategoriji pripada odlika na koju se sentiment odnosi, jer su se neke riječi i izrazi mogli koristiti za izražavanje sentimenata prema više odlika, u ovisnosti o kontekstu. No, kako ručna analiza, premda zahtjeva dosta vremena, predstavlja zlatni standard pri analizi sentimenata, s pravom se može pretpostaviti da su dobiveni rezultati, unatoč svim navedenim poteškoćama, precizniji i pouzdaniji od onih koji bi se dobili automatskom analizom sentimenata.

4.5. Daljnja istraživanja

Rezultati dobiveni u ovom istraživanju otvorili su brojna pitanja o tome kako novinski portali mogu poboljšati uvjete za razvijanje kvalitetne konverzacije građana novinara, poglavito u vrijeme predizbornih kampanja, koliko različita sučelja pospješuju ili slabe kvalitetu konverzacije i kakva je uloga moderatora novinskih portala u smanjenju zastupljenosti „ad hominem“ argumenata. U ovom istraživanju bili su nepoznati demografski podaci o građanima novinarima, pa bi u nekom kasnijem istraživanju na hrvatskim novinskim portalima u vrijeme

predizbornih kampanja bilo korisno proučiti odlike konverzacije građana novinara s obzirom na njihov spol, godine, stupanj naobrazbe, vjerska ili politička uvjerenja. Također, bilo bi zanimljivo istražiti putem ankete, fokus grupa ili dubinskih intervjua s građanima novinarima njihovu motivaciju za participaciju tijekom predizbornih kampanja te saznati što očekuju od takvih oblika aktivnosti, kakve ih teme i zašto angažiraju, stupaju li i zašto u konverzaciju s drugim građanima novinarima, kako se odnose prema „ad hominem“ argumentima i sl. Posebno bi zanimljivo bilo istražiti odnos između profesionalnih novinara i građana novinara na hrvatskim novinskim portalima u vrijeme predizborne kampanje: koliko profesionalni novinari čitaju komentare građana novinara i sudjeluju li i sami u konverzaciji koja se razvija na novinskim portalima, utječe li na njihove profesionalne aktivnosti sadržaj koji napišu građani novinari i koliko sadržaji komentara građana novinara za profesionalne novinare mogu biti izvor korisnih informacija. Nadalje, bilo bi zanimljivo zasebno istražiti populaciju građana koji nikada ne pišu komentare, ali posjećuju novinske portale, poglavito u vrijeme predizborne kampanje, i saznati kako se odnose prema sadržaju komentara koje pišu građani novinari: čitaju li ih i zašto, zbog čega ne sudjeluju u konverzaciji, predstavljaju li im takvi sadržaji izvor korisnih informacija, utječu li sadržaji komentara na njihove stavove o pojedinim kandidatima.

Zanimljivo bi bilo na početku predizborne kampanje provesti anketu među posjetiteljima novinskih portala koji redovito čitaju novinske članke o kandidatima i utvrditi njihove stavove o kandidatima, a zatim ih na kraju predizborne kampanje ponovno anketirati i utvrditi postoje li i u kolikoj mjeri promjene u stavovima, javljaju li se one češće u skupini posjetitelja koji pišu komentare, u skupini koja samo čita komentare ili u skupini koja uopće ne čita komentare.

Predmet novih istraživanja mogao bi biti i odnos političara prema participativnom novinarstvu u vrijeme predizborne kampanje: koliko sami kandidati čitaju komentare građana novinara, sudjeluju li u konverzacijama, utječu li komentari građana novinara na njihovo ponašanje i postupanje u javnosti i sl.

Ovo je istraživanje otvorilo i nove mogućnosti na području računarske lingvistike, budući da je izgrađen rječnik od 4913 hrvatskih riječi i izraza koji izražavaju sentimente prema političarima i njihovim odlikama, a mogao bi se primijeniti za automatsku analizu sentimenata građana novinara na hrvatskim novinskim portalima tijekom predizborne kampanje.

5. Zaključak

Istraživanje povezanosti participativnog novinarstva i izbornih rezultata u studiji više slučajeva (eng. cross-case analysis) na pet hrvatskih novinskih portala: 24 sata, Indeks. T-portal, Slobodna Dalmacija i Dalmacija News, pokazalo je da hrvatska internetska javna sfera na novinskim portalima uistinu predstavlja mrežu za izmjenu informacija i stavova, kako ju je opisao Habermas (1996). To je prostor konverzacije kao posebnog oblika diskursa u kojem se primaju i prenose poruke (Zymnaja, 2001, navedeno u Milevskaya, 2002) između više osoba, a taj se proces odvija objavljivanjem novinskih članaka čiji su autori profesionalni novinari i objavljivanjem komentara čiji su autori neprofesionalni novinari koje nazivamo „građani novinari". Na taj se način i u hrvatskom mrežnom prostoru manifestira „mrežno novinarstvo" (eng. online journalism), u kojem ulogu novinara preuzimaju obični građani (Deuze, 2003), i kao njegov poseban oblik na novinskim se portalima manifestira „ participativno novinarstvo" (eng. participatory journalism), u kojem građani novinarsku aktivnost ostvaruju u suradnji s profesionalnim novinarima, budući da profesionalni novinari objavom novinskih članaka određuju teme o kojima se vodi konverzacija (Henig, 2005; Nip, 2006, Friedland & Kim, 2009). Jedna je od zadaća ovog istraživanja bila utvrditi odlike konverzacije građana novinara koja se razvija uz objavljene članke na novinskim portalima u vrijeme predizborne kampanje za splitskog gradonačelnika 2013. te saznati koliko je takva konverzacija bila slična idealu javne rasprave za koju Habermas (1984, p. 25) kaže da isključuje svaki oblik sile osim sile boljeg argumenta. Stupajući u konverzaciju jedni s drugima građani bi novinari u javnoj raspravi trebali biti spremni saslušati i uvažiti tuđe argumente te suočeni s boljim argumentom od svoga trebali bi biti spremni promijeniti stav (Habermas, 1991). Visoka argumentiranost konverzacije pretpostavlja i njenu visoku interaktivnost, ali visoka interaktivnost ne mora biti nužno znak visoke argumentiranosti, jer građani novinari u konverzacijama na novinskim portalima mogu više vrijeđati i napadati jedni druge nego li izmjenjivati argumentirane komentare, što je ovo istraživanje i pokazalo. I dok se prosječna interaktivnost, koja se mjerila kao udio komentara koji predstavljaju odgovore na prethodne, mijenjala od portala do portala, varirajući između najniže na portalu Dalmacija News (20, 59%) i najviše na portalu 24 sata (41,19%), prosječna se argumentiranost kretala između najniže na portalu Indeks (5,13%) i najviše na portalu Slobodna Dalmacija (15,40%), što znači da je u najboljem slučaju prosječno u konverzacijama bilo svega 15, 40% argumentiranih komentara. Osim brojanja komentara koji su predstavljali odgovore na prethodne i analize sadržaja komentara radi utvrđivanja argumentiranosti, za svaku se konverzaciju na temelju njenih strukturalnih pokazatelja računala i razina polemičnosti koja

je bila povezana s dubinom sloja konverzacije i brojem građana novinara u tom sloju (Gomez et al., 2010). Naime, konverzacija građana na novinskom portalu strukturalno izgleda poput radijalnog stabla u čijem je središtu objavljeni članak, u prvom su sloju komentari na taj članak, u drugome odgovori na komentare u prvom sloju i tako redom. Na svim je portalima razina polemičnosti bila niska i varirala je između 1,22 (Dalmacija News) i 2,75 (24 sata), što znači da se u najboljem slučaju u prosječnoj konverzaciji postizao samo drugi sloj konverzacije u kojem je bilo barem dvoje građana novinara. Nadalje, u istraživanju je provedena i ručna analiza „prosudba i ideja obojanih emocijama" (Boiy et al., 2007: 350) ili sentimenata koje su građani novinari u komentarima izražavali jedni prema drugima, a koja je pokazala da su na svim istraživanim portalima prema građanima novinarima izraženi pretežito negativni sentimenti, jer su prosječne vrijednosti SO komentara koje su se odnosile na građane novinare bile negativne. Tako je prosječna SO komentara koja je predstavljala brojčano izraženu jakost i predznak sentimenta bila najviša na portalu Slobodna Dalmacija (-10), a najmanja na portalu 24 sata (-0,513). Negativni se sentimenti mogu povezati s uporabom argumenata „ad hominem" kojim se ne napada tuđi argument nego osoba koja ga je izrekla (Kišiček, 2013), tako da zbog svih ovih pokazatelja možemo zaključiti da je konverzacija građana novinara na istraživanim novinskim portalima tijekom predizborne kampanje za splitskog gradonačelnika 2013. bila daleko od ideala javne rasprave, zbog čega se **prihvaća** hipoteza **H6** o tome da je konverzacija građana novinara na istraživanim portalima imala nisku razinu javne rasprave.

U ovom su se istraživanju, osim odlika konverzacije građana novinara na novinskim portalima, analizirali i sentimenti građana izraženi prema kandidatima za izbor splitskog gradonačelnika 2013. Pokazalo se da su prevladavali negativni sentimenti za sve kandidate, osim za Marijanu Puljak, te da su, kao i u slučaju odlika konverzacije građana novinara, s obzirom na sentimente izražene prema pojedinim kandidatima postojale razlike od portala do portala. Ono što sve istraživane portale povezuje je izrazita dominacija članaka i broja komentara o Željku Kerumu, kao i dominacija broja građana novinara koji su pisali komentare o njemu. Također, o nekim je kandidatima poput Pere Vučice i Marija Popovića bilo malo novinskih članka na lokalnim novinskim portalima, a na nacionalnima ih uopće nije bilo. Na temelju analize sentimenata izraženih prema kandidatima i njihovim odlikama koje su uočene tijekom analize, može se reći da je na svim portalima na kojima su bili o njoj objavljeni novinski članci, neosporno „pobijedila" dotad široj javnosti nepoznata Marijana Puljak, koja je ujedno predstavljala i iznenađenje lokalnih izbora 2013., jer su kandidati s njene liste uspjeli ući u Gradsko vijeće, a ona sama postala je gradska vijećnica. I dok je za sve ostale kandidate na novinskim portalima prosječna SO komentara bila negativna, zbog čega se **prihvaća** hipoteza

H4 o dominaciji negativnih sentimenata, za nju je na dva od tri portala prosječna SO komentara bila pozitivna. Među svim istraživanim portalima uočena je još jedna poveznica – građani su novinari u kategoriji Domoljublje najlošije ocijenili SDP-ovog kandidata Ivu Baldasara, a u kategoriji Kriminalnost uglavnom najlošije HDZ-ovog kandidata Vjekoslava Ivaniševića.

Kao što je već kazano, na svim je novinskim portalima uočena izrazita dominacija broja novinskih članaka o Željku Kerumu, ali što je novinski portal imao manji broj posjetitelja to je dominacija članaka o njemu bila manja, pa je tako najmanje bila izražena na portalu Dalmacija News. Da bi se utvrdila povezanost participativnog novinarstva i izbornih rezultata odabrani su samo oni portali koji su objavili članke o svim kandidatima: Slobodna Dalmacija i Dalmacija News. Primjenom Spearmanovog testa korelacije uočena je povezanost između izbornih rezultata i varijabli participativnog novinarstva: broja članaka objavljenih o kandidatima, broja komentara o kandidatima, te broja prema kandidatu pozitivno i negativno orijentiranih građana novinara. Velika je povezanost utvrđena uglavnom na novinskom portalu Slobodna Dalmacija: između broja prema kandidatu negativno orijentiranih građana novinara i izbornih rezultata (0,79), između broja komentara o kandidatu i izbornih rezultata (0,85) te između broja građana novinara koji su komentirali kandidata i izbornih rezultata. Na portalu Dalmacija News vrlo je dobra povezanost uočena između broja objavljenih članaka o kandidatu i izbornih rezultata (0,84). Zbog ovih su rezultata **prihvaćene** hipoteze o povezanosti participativnog novinarstva i izbornih rezultata (**H1**), o povezanosti broja prema kandidatu pozitivno orijentiranih građana novinara i izbornih rezultata (**H2**) te o povezanosti broja prema kandidatu negativno orijentiranih građana novinara i izbornih rezultata (**H3**), s time da treba naglasiti kako je veća povezanost utvrđena između izbornih rezultata i broja prema kandidatu negativno orijentiranih građana novinara nego li pozitivno orijentiranih. Pokazalo se, kao i u sličnom portugalskom istraživanju (Carvalho et. al., 2011), da nije bitan toliko predznak sentimenta izražen prema kandidatu koliko njegova količina izražena u velikom broju komentara, što se povezuje i s većim brojem građana novinara koji komentiraju tog kandidata. Kruskal-Wallis test je pokazao da nema sličnosti u raspodjeli rezultata za SO komentara o građanima novinarima i o kandidatima za koje je bilo dovoljno mjerenja (građana novinara koji su ih komentirali) na svim istraživanim portalima, što znači da građani novinari na istraživanim portalima nisu pripadali istoj populaciji birača. Zbog toga je **odbačena** hipoteza **H5** o sličnosti komentara na svim istraživanim portalima.

Naposljetku, može se zaključiti da je ovo istraživanje utvrdilo kako konverzacija građana novinara na novinskim portalima tijekom predizborne kampanje za izbor splitskog gradonačelnika 2013. nije imala dovoljno odlika javne rasprave, da su u konverzaciji izraženi

dominantno negativni sentimenti, da građani novinari na istraživanim portalima ne pripadaju istoj populaciji birača te da je postojala povezanost između participativnog novinarstva i izbornih rezultata. Ta se povezanost utvrdila na temelju istraživanja mnijenja izraženih u komentarima građana novinara te na temelju broja objavljenih članaka o kandidatima, broja komentara o njima i broja građana koji su ih komentirali.

Popis korištenih izvora i literature

24 sata, < www.24sata.hr>, [pristupljeno 10.06.2013]

Abdulla, N. A., Al-Ayyoub,M. & Al-Kabi, M. N., (2014), An extended analytical study of arabic sentiments, *International Journal of Big Data Intelligence 1, [Online], 1 (1-2), pp.* 103-113, <raspoloživo na: https://www.researchgate.net/profile/Mohammed_Al-Kabi/publication/264832333_An_extended_analytical_study_of_Arabic_sentiments/links/54253a780cf26120b7ac7f46.pdf>, [pristupljeno 23.04.2015.].

Abdul-Mageed, M. M., (2008), Online News Sites and Journalism 2.0: Reader Comments on Al Jazeera Arabic. tripleC: Communication, Capitalism & Critique, Open Access Journal for a Global Sustainable Information Society, [Online], 6 (2), pp. 59-76, <raspoloživo na: http://www.triple-c.at/index.php/tripleC/article/download/78/70>, [pristupljeno 16.08.2014.].

Ackerman, B.& Fishkin, J. S., (2002), Deliberation day, *Journal of Political Philosophy*, [Online], 10 (2), pp.129-152., <raspoloživo na: http://digitalcommons.law.yale.edu/cgi/viewcontent.cgi?article=1161&context=fss_papers>, [pristupljeno 10.04.2014.].

Anić, V. (1991), Rječnik hrvatskoga jezika, Zagreb: Novi liber.

Balasubramanyan, R. et al., (2012), Modeling polarizing topics: When do different political communities respond differently to the same news?, [Online], *ICWSM*, <raspoloživo na: http://cs.cmu.edu/~wcohen/postscript/icwsm-2012.pdf>, [pristupljeno 11.03.2015.].

Barzilai-Nahon, K., (2008), Toward a theory of network gatekeeping: A framework for exploring information control, Journal of the American society for information science and technology, [Online], 59 (9), pp. 1493-1512, <raspoloživo na: https://pdfs.semanticscholar.org/3e87/da50eb306ed6dc8326b2fd63c75aaf523c80.pdf>, [pristupljeno 03.03.2014.].

Beaver, D. & Frazee, J., (2011), Semantics, The Handbook of Computational Linguistics, Mitkov, R. (Ed.), [Online], <raspoloživo na: http://semanticsarchive.net/Archive/DAzYmYzO/semantics_oup.pdf>, [pristupljeno 07.06.2014.].

Benn, S. & Jones, R., (2009), The role of symbolic capital in stakeholder disputes: Decision-making concerning intractable wastes, *Journal of environmental management, [Online],* 90 (4), pp. 1593-1604, <raspoloživo na: http://epress.lib.uts.edu.au/research/bitstream/handle/10453/8570/2008007866.pdf?sequence=1>, [pristupljeno 10.05.2014.].

Bishop, H. & Jaworski, A., (2003), We beat'em': nationalism and the hegemony of homogeneity in the British press reportage of Germany versus England during Euro 2000, *Discourse & Society,* [Online], 14 (3), pp. 243-271, <raspoloživo na: http://www.labwales.org.uk/encap/resources/publications/jaworski-adam/papers/bishop%20and%20jaworski%202003.pdf >, [pristupljeno 10.07.2014.].

Blumler, J. G. & Gurevitch, M., (2001), The new media and our political communication discontents: Democratizing cyberspace, *Information, Communication & Society*, [Online], 4 (1), pp. 1-13, <raspoloživo na: http://www.tandfonline.com/doi/pdf/10.1080/713768514>, [pristupljeno 12.06.2014.].

Boiy, E. et al., (2007), Automatic Sentiment Analysis in On-line Text, *ELPUB, [Online],* pp. 349 – 360, <raspoloživo na: https://www.researchgate.net/profile/Bob_Martens/publication/242501831_Openness_in_Digital_Publishing_Awareness_Discovery_and_Access_-_Proceedings_of_the_11th_International_Conference_on_Electronic_Publishing_held_in_Vienna_-_ELPUB_2007_Vienna_Austria_June_13-15_2007_Pro/links/54e9fdd50cf2f7aa4d5642a9.pdf#page=359>, [pristupljeno 05.05.2014.].

Caliandro, A. & Gandini, A., (2016), Qualitative research in digital environments: a research toolkit, Routledge.

Carvalho, P. et al., (2011), Liars and saviors in a sentiment annotated corpus of comments to political debates, Proceedings of the 49th Annual Meeting of the Association for Computational Linguistics: Human Language Technologies: short papers-Volume 2, [Online], Association for Computational Linguistics, <raspoloživo na: https://www.researchgate.net/profile/Mohammed_Korayem/publication/260298632_Abbasi_Ahmed_Hsinchun_Chen_and_Arab_Salem_Sentiment_analysis_in_multiple_languages_Feature_selection_for_opinion_classification_in_web_forums_ACM_Transactions_on_Information_Systems_TOIS_2008_26_3/links/565c4f2208ae4988a7bb6984.pdf#page=604>, [pristupljeno 21.04.2015.].

Clift, S., (2003), E-democracy, e-governance and public net-work, Publicus. net, [Online], <raspoloživo na: http://www.opensourcejahrbuch.de/Archiv/2006/abstracts/kapitel_04/abstracts/2004/pdfs/IV-5-Clift.pdf>, [pristupljeno 11.08.2014.].

Collins, L. & Nerlich, B., (2015), Examining user comments for deliberative democracy: A corpus-driven analysis of the climate change debate online, *Environmental Communication, [Online], 9 (2),* pp. 189-207, <raspoloživo na: http://www.tandfonline.com/doi/pdf/10.1080/17524032.2014.981560?needAccess=true>, [pristupljeno 17.12.2015.].

Dahlgren, P., (2005), The Internet, public spheres, and political communication: Dispersion and deliberation, Political communication, [Online], 22 (2), pp. 147-162, <raspoloživo na: ftp://24.166.108.44/TAU/Political%20Communications/Dahlgren.pdf>, [pristupljeno 11.03.2014.].

Dalmacija News, < www.dalmacijanews.hr>, [pristupljeno 16.06.2013]

Delli Carpini, M. X. & Williams, B. A., (2001), Let us infotain you: Politics in the new media age, Mediated politics: Communication in the future of democracy, [Online], pp.160-181. New York : Cambridge University Pres <raspoloživo na: http://repository.upenn.edu/cgi/viewcontent.cgi?article=1013&context=asc_papers>, [pristupljeno 05.08.2014.].

Deuze, M., (2003), The Web and its journalisms: Considering the consequences of different types of news media online, New Media & Society, [Online], 5 (2), pp. 203–230. <raspoloživo na: http://www.multidesign.org/lib/Mark%2BDeuze%2B-%2BThe%2Bweb%2Band%2Bits%2Bjournalisms.pdf>, [pristupljeno 10.06.2014.].

Diamant, E., (2012), Let us first agree on what the term" semantics" means: An unorthodox approach to an age-old debate, arXiv preprint, [Online], <raspoloživo na: https://arxiv.org/pdf/1201.0328>, [pristupljeno 16.06.2014.].

Ding, X., Bing, L. & Yu, P. S., (2008), A holistic lexicon-based approach to opinion mining, *Proceedings of the 2008 International Conference on Web Search and Data Mining*, [Online], ACM, <raspoloživo na: http://www.cs.uic.edu/~liub/FBS/opinion-mining-final-WSDM.pdf>, [pristupljeno 05.09.2014.].

Dooley, R. A. & Levinsohn, S. H., (2000), Analyzing discourse: a manual of basic concepts, *SIL International and University of North Dakota*, [Online], <raspoloživo na: https://www.researchgate.net/profile/Robert_Dooley/publication/248657183_Analyzing_Discourse_A_Manual_of_Basic_Concepts/links/562e70e908aef25a244448f7.pdf>, [pristupljeno 02.05.2014.].

Dryzek, J. S., (2000), Deliberative democracy and beyond: Liberals, critics, contestations, Oxford University Press on Demand.

Entman, R. M. & Herbst, S., (2001), Reframing public opinion as we have known it, *Mediated politics: Communication in the future of democracy,* [Online], pp. 203-225, <raspoloživo na: http://pendientedemigracion.ucm.es/info/socvi/BOUZA/NUEVA1/AgPoMe/textos_APM/6/Reframing.pdf>, [pristupljeno 11.04.2014.].

Erikson, R. S. & Tedin, K. L., (2015), American public opinion: Its origins, content and impact, Routledge.

Erjavec, K. & Poler-Kovačič, M., (2013), Abuse of Online Participatory Journalism in Slovenia: Offensive Comments under News Items, *Medijska istraživanja, [Online], 19 (2),* pp. 55-74, <raspoloživo na: http://hrcak.srce.hr/file/165843>, [pristupljeno 20.08.2015.].

Financijski podaci i poslovne informacije, < www.bisnode.hr>, [pristupljeno 10.06.2013]

Fishkin, J. S. & Luskin, R. C., (2005), Experimenting with a democratic ideal: Deliberative polling and public opinion, *Acta Politica,* [Online], 40 (3), pp. 284-298, <raspoloživo na: https://www.uvm.edu/~dguber/POLS234/articles/fishkin.pdf >, [pristupljeno 11.04.2014.].

Freelon, D. G., (2010), Analyzing online political discussion using three models of democratic communication, *New Media & Society*, [Online], 12(7), pp. 1172-1190, <raspoloživo na: http://www.ciberdemocracia.net/victorsampedro/wp-content/uploads/2012/12/ANALYZING_ONLINE_POLITICAL_DISCUSSION.pdf>, [pristupljeno 17.11.2014.].

Friedland, L. & Kim, N., (2009), Citizen journalism, *Encyclopedia of journalism*, pp. 297-302.

Galston, W. A., (2003), If political fragmentation is the problem, is the Internet the solution, The civic web: Online politics and democratic values, pp. 35-44.

Gemius Audience , < http://archive.audience.com.hr/pages/display/visitors>, [pristupljeno 02.06.2013]

Gensler, H. J., (2012), *Introduction to logic*, Routledge, [Online] , <raspoloživo na: http://14.139.206.50:8080/jspui/bitstream/1/2383/1/Harry%20J.%20Gensler%20-%20Introduction%20to%20Logic,%202nd%20Edition%202010.pdf>, [pristupljeno 10.08.2015.].

Godde, C., Lazaridou, K. & Krestel, R., (2016), Classification of German newspaper comments, Proceedings of the Conference Lernen, Wissen, Daten, Analysen (LWDA), [Online], Hasso Plattner Institut, Potsdam, S., <raspoloživo na: http://ceur-ws.org/Vol-1670/paper-64.pdf>, [pristupljeno 05.06.2014.].

Gonzalez-Bailon, S., Kaltenbrunner, A. & Banchs, R. E., (2010), The structure of political discussion networks: a model for the analysis of online deliberation, *Journal of Information Technology*, [Online], 25 (2), pp. 230-243. <raspoloživo na: http://www.dtic.upf.edu/~akalten/gonzalez_bailon_etal2010.pdf>, [pristupljeno 07.06.2014.].

Govier, T., (2013), A practical study of argument, Cengage Learning, [Online] , <raspoloživo na: http://www.kalabakas.dk/files/Books/A%20Practical%20Study%20of%20Argument.pdf >, [pristupljeno 20.07.2015.].

Graber, D. et al., (2003), The Internet and politics: Emerging perspectives, Academy and the Internet, pp. 90-119.

Graham, T., (2008), Needles in a haystack: A new approach for identifying and assessing political talk in nonpolitical discussion forums, Javnost-The Public, [Online], 15 (2), pp. 17-36., <raspoloživo na: https://www.researchgate.net/profile/Todd_Graham3/publication/242782911_Needles_in_a_haystack_a_new_approach_for_identifying_and_assessing_political_talk_in_non-political_discussion_forums/links/00b49538b2ba75b319000000.pdf>, [pristupljeno 10.06.2014.].

Ha, S., (2003), How to Think About Political Candidates: A Texas Primary Election Study, 1st International Symposium Communication in the Millenium, [Online], Eskişehir: Anadolu Üniversitesi Yayınları, pp. 329-343., <raspoloživo na: http://cim.anadolu.edu.tr/pdf/2003/21.pdf>, [pristupljeno 21.06.2014.].

Habermas, J., (1984), The theory of communicative action: Vol. 1. Reason and the rationalization of society, *Boston: Beacon*, <raspoloživo na: http://www.dphu.org/uploads/attachements/books/books_2795_0.pdf>, [pristupljeno 07.05.2014.].

Habermas, J., (1991), The structural transformation of the public sphere: An inquiry into a category of bourgeois society, Cambridge: MIT Press.

Habermas, J., (1996), Between Facts and Norms: Contributions to a Discourse Theory of Law and Democracy, Communication Theory, [Online], 16, <raspoloživo na: http://blogs.unpad.ac.id/teddykw/files/2012/07/J%C3%BCrgen-Habermas-Between-Facts-and-Norms.pdf>, [pristupljeno 07.06.2014.].

Habermas, J., (2006), Political communication in media society: Does democracy still enjoy an epistemic dimension? The impact of normative theory on empirical research, Communication Theory, [Online], 16 (4), <raspoloživo na: http://mt.educarchile.cl/mt/jjbrunner/archives/1-habermas_deliberation2006.pdf>, [pristupljeno 22.06.2014.].

Hallin, D. C. & Mancini, P., (2004), *Comparing media systems: Three models of media and politics*, [Online], Cambridge university press, <raspoloživo na: https://pdfs.semanticscholar.org/dd5f/af65bdee73e354fc0f07c2397febfe51bef7.pdf >, [pristupljeno 19.03.2015.].

Herscovitz, H., (2009), Brazilian news portals characteristics, Brazilian Journalism Research, [Online], 5 (1), <raspoloživo na: https://bjr.sbpjor.org.br/bjr/article/download/183/182>, [pristupljeno 17.10.2014.].

Hoffman, L. H., (2006), Is Internet content different after all? A content analysis of mobilizing information in online and print newspapers, Journalism & Mass Communication Quarterly, [Online], 83 (1), <raspoloživo na: http://sites.google.com/site/lhhoff/final_Hoffman2006pub.pdf>, [pristupljeno 07.03.2014.].

Holtz, P., Kronberger, N. & Wagner, W., (2012), Analyzing internet forums, Journal of Media Psychology, [Online], <raspoloživo na: https://www.researchgate.net/profile/Peter_Holtz/publication/254735438_Analyzing_Internet_Forums_A_Practical_Guide/links/00b7d529e1d82338d8000000.pdf>, [pristupljeno 15.02.2015.].

Hoskin, T., (2012), Data Types, [Online], <raspoloživo na: http://www.mayo.edu/mayo-edu-docs/center-for-translational-science-activities-documents/berd-5-4.pdf>, [pristupljeno 21.04.2014.].

Houston, J. B., Hansen, G. J. & Nisbett, G. S., (2011), Influence of user comments on perceptions of media bias and third-person effect in online news, *Electronic News, [Online], 5 (2),* pp. 79-92, <raspoloživo na: https://www.researchgate.net/profile/J_Brian_Houston/publication/220010178_Influence_of_User_Comments_on_Perceptions_of_Media_Bias_and_Third-Person_Effect_in_Online_News/links/00463535534aef1aec000000.pdf>, [pristupljeno 18.03.2015.].

Hughes, M. G. et al., (2016), Examining Online Communication: A Method for the Quantitative, Mixed Methods Research for Improved Scientific Study, [Online], <raspoloživo na: http://www.academia.edu/download/38393454/Method_Article_Final_0715.pdf>, [pristupljeno 15.10.2016.].

Indeks, < www.index.hr>, [pristupljeno 12.06.2013]

Janssen, D. & Kies, R., (2005), Online forums and deliberative democracy, Acta política, [Online], 40 (3), pp. 317-335, <raspoloživo na: http://steunpuntbov.be/rapport/s0506006_onlineforums.pdf>, [pristupljeno 12.06.2014.].

Jensen, J. L., (2014), Online deliberation and beyond? A time-based and comparative study of Danish political debates, MedieKultur Journal of media and communication research, [Online], 42 (6), <raspoloživo na: http://www.soundeffects.dk/index.php/mediekultur/article/viewFile/16327/15173 >, [pristupljeno 12.06.2014.].

Jørgensen, M. W. & Phillips, L. J., (2002), *Discourse analysis as theory and method*, [Online], Sage, <raspoloživo na: http://www.aclweb.org/anthology/J79-1082 >, [pristupljeno 10.05.2014.].

Kim, J., Wyatt, R.O. & Katz, E., News, talk, opinion, participation: The part played by conversation in deliberative democracy, *Political communication,* [Online], 16 (4), pp. 361-385, <raspoloživo na: http://www.academia.edu/download/31111264/jkim_paper_04.pdf>, [pristupljeno 03.06.2014.].

Kišiček, G., (2013), Ad hominem arguments in political discourse, Istraživanja govora-Speech Research, [Online] , <raspoloživo na: www.uni-saarland.de/fileadmin/.../Paper_Kisicek_Gabrijela.pdf>, [pristupljeno 20.08.2015].

Kleut, J. & Milinkov, S., (2013), Co-construction and Deconstruction of Poverty on Serbian News Websites, Medijska istraživanja : znanstveno-stručni časopis za novinarstvo i medije, [Online], 19 (2), pp. 75-98, <raspoloživo na: http://hrcak.srce.hr/112383>, [pristupljeno 11.10.2015.].

Krippendorff, K., (2004), *Content analysis: An introduction to its methodology*, [Online], Sage, <raspoloživo na: http://www.academia.edu/download/35270347/Content_Analysis_-an_introduction.pdf>, [pristupljeno 08.03.2015.].

Krippendorff, K., (2005), The social construction of public opinion, *Kommunikation über Kommunikation*. VS Verlag für Sozialwissenschaften, [Online], pp. 129-149, <raspoloživo na: http://repository.upenn.edu/cgi/viewcontent.cgi?article=1077&context=asc_papers>, [pristupljeno 18.09.2014.].

Kristiansen, M.& Bloch-Poulsen, J., (2004), Self-referentiality as a power mechanism Towards dialogic action research, *Action Research, [Online],* 2 (4), pp. 371-388, <raspoloživo na: http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.927.7007&rep=rep1&type=pdf>, [pristupljeno 11.06.2014.].

Kruskal, W. H. & Wallis, W. A., (1952), Use of ranks in one-criterion variance analysis, Journal of the American statistical Association, [Online], 47 (260), pp. 583-621, <raspoloživo na: http://webspace.ship.edu/pgmarr/Geo441/Readings/Kruskal%20and%20Wallis%201952%20-%20Use%20of%20Ranks%20in%20One-Criterion%20Variance%20Analysis.pdf>, [pristupljeno 08.06.2014.].

Kuhnen, C. M. & Niessen, A., (2012), Public opinion and executive compensation, Management Science, [Online], 58 (7), pp. 1249-1272, <raspoloživo na: https://www.econstor.eu/bitstream/10419/69237/1/735594988.pdf>, [pristupljeno 21.05.2014.].

Landsberger, J., (2001), Integrating a Web-based Bulletin Board into your Class: A guide for Faculty, *TechTrends*, 45 (5).

Lemann, N., (2006), Amateur hour, The New Yorker, [Online], 7 (8), <raspoloživo na: http://www.personal.psu.edu/faculty/c/a/caw43/ENGL420/Journalism.doc>, [pristupljeno 05.04.2015.].

Lewiński, M., (2010), *Internet political discussion forums as an argumentative activity type: A pragma-dialectical analysis of online forms of strategic manoeuvring in reacting critically, [Online],* Rozenberg Publishers, <raspoloživo na: http://dare.uva.nl/document/173817>, [pristupljeno 11.06.2014.].

Lewis, S. C., Kaufhold, K. & Lasorsa, D. L., (2010), Thinking about citizen journalism: The philosophical and practical challenges of user-generated content for community newspapers, Journalism Practice, [Online], 4 (2), pp. 163-179, <raspoloživo na: http://hdl.handle.net/11299/123405>, [pristupljeno 02.04.2014.].

Li, Y. M., Liao, T. F. & Lai, C. Y., (2012), A social recommender mechanism for improving knowledge sharing in online forums, Information Processing & Management, [Online], 48 (5), pp. 978-994, <raspoloživo na: http://trouvus.com/wp-content/uploads/2016/03/A-social-recommender-mechanism-for-improving-knowledge-sharing-in-online-forums.pdf>, [pristupljeno 02.04.2014.].

Liu, B., (2012), Sentiment analysis and opinion mining, *Synthesis Lectures on Human Language Technologies,* [Online], 5 (1), pp. 1-167, <raspoloživo na: http://neerci.ist.utl.pt/neerci_shelf/MERC/AEP_Gestao%20das%20Redes,%20da%20Informacao%20e%20dos%20Servicos/2%20Semestre/Extracao%20e%20Analise%20de%20Dados%20Web/Books/SentimentAnalysis-and-OpinionMining.pdf>, [pristupljeno 12.05.2014.].

Manosevitch, E. & Walker, D., (2009), Reader comments to online opinion journalism: A space of public deliberation, *International Symposium on Online Journalism,* [Online], 10, <raspoloživo na: http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.602.5737&rep=rep1&type=pdf>, [pristupljeno 27.09.2014.].

Manza, J. & Cook, F. L., (2002), A democratic polity? Three views of policy responsiveness to public opinion in the United States, *American Politics Research, [Online],* 30 (6), pp. 630-667, <raspoloživo na: http://www.cassr.as.nyu.edu/docs/IO/3858/A_Democratic_Polity.pdf>, [pristupljeno 12.11.2015.].

Marshall, M., (1996), Sampling for qualitative research, Family practise, 13 (6), pp. 522-526.

McCombs, M., (1997), Building consensus: The news media's agenda-setting roles, Political Communication, [Online], 14(4), pp. 433-443, <raspoloživo na: http://blog.roodo.com/research_information/7496232b.pdf>, [pristupljeno 28.08.2014.].

Meguebli, Y. et al., (2014), Unsupervised approach for identifying users' political orientations, *European Conference on Information Retrieval*, [Online], Springer International Publishing, <raspoloživo na: https://pdfs.semanticscholar.org/846b/3310b53bb483a299fb5f19b42ae5dde453dd.pdf>, [pristupljeno 20.09.2015.].

Milas, G., (2005), Istraživačke metode u psihologiji i drugim društvenim znanostima, Jastrebarsko: Naklada Slap.

Milevskaya, T. V., (2002), Discourse, speech activity, text, Bulletin of Russian Communication Association "THEORY OF COMMUNICATION AND APPLIED COMMUNICATION", [Online], pp. 67 -70, Rostov-on-Don: Institute of Management, Business and Law Publishing, <raspoloživo na: http://www.russcomm.ru/eng/rca_biblio/m/milevskaya01_eng.shtml >, [pristupljeno 16.05.2014.].

Milioni, D. L., Vadratsikas, K. & Papa, V., (2012), Their two cents worth': Exploring user agency in readers' comments in online news media, *Observatorio (OBS*),* [Online], 6 (3), <raspoloživo na: http://obs.obercom.pt/index.php/obs/article/download/591/514>, [pristupljeno 10.05.2015.].

Murphy, E. & Ciszewska-Carr, J., (2005), Sources of Difference in Reliability: Identifying Sources of Difference in Reliability in Content Analysis of Online Asynchronous Discussions, *International Review of Research in Open and Distance Learning,* [Online], 6 (2), <raspoloživo na: http://files.eric.ed.gov/fulltext/EJ846843.pdf>, [pristupljeno 11.03.2015.].

Nickels, H., (2005), Framing the refugee and asylum question in Luxembourg: an interactive approach to framing theory, [Online], <raspoloživo na: http://dare.uva.nl/document/2/33917>, [pristupljeno 11.05.2016.].

Nip, J. YM., (2006)., EXPLORING THE SECOND PHASE OF PUBLIC JOURNALISM 1, Journalism Studies 7 (2), [Online], pp. 212-236, <raspoloživo na: http://sydney.edu.au/arts/media_communications/downloads/documents/06_Exploring_second_phase_public%20_Journalism_JS.pdf>, [pristupljeno 16.04.2014.].

Noci, J. D. et al., (2012), Comments in news, democracy booster or journalistic nightmare: Assessing the quality and dynamics of citizen debates in Catalan online newspapers, *International Symposium on Online Journalism,* [Online], 2 (1), <raspoloživo na: https://online.journalism.utexas.edu/journals/ISOJ_Journal_V2_N1_2012_Spring.pdf#page=46>, [pristupljeno 11.04.2014.].

Noor, R., (2016), Citizen Journalism: News Gathering by Amateurs, Handbook of Research on Citizen Engagement and Public Participation in the Era of New Media, IGI Global.

Page, B. I. & Shapiro, R. Y., (1983), Effects of public opinion on policy, *American political science review,* [Online], 77 (1), pp. 175-190, <raspoloživo na: http://www.uvm.edu/~dguber/POLS234/articles/page.pdf>, [pristupljeno 06.04.2014.].

Papacharissi, Z., (2004), Democracy online: Civility, politeness, and the democratic potential of online political discussion groups, New Media & Society, [Online], 6 (2), pp. 259-283, <raspoloživo na: http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.902.7553&rep=rep1&type=pdf>, [pristupljeno 08.04.2014.].

Park, J. & Cardie, C., (2014), Identifying appropriate support for propositions in online user comments, *Proceedings of the First Workshop on Argumentation Mining*, [Online], <raspoloživo na: https://www.aclweb.org/anthology/W/W14/W14-21.pdf#page=41>, [pristupljeno 17.04.2015.].

Park, S. et al., (2011), The politics of comments: predicting political orientation of news stories with commenters' sentiment patterns, Proceedings of the ACM 2011 conference on Computer supported cooperative work, [Online], ACM, <raspoloživo na: https://pdfs.semanticscholar.org/c849/e41faef43945fcb02a12bae0ca6da50fc795.pdf>, [pristupljeno 05.09.2014.].

Pennebaker, J. W., Mehl, M. R. & Niederhoffer, K. G., (2003), Psychological aspects of natural language use: Our words, our selves, *Annual review of psychology*, [Online], 54 (1), pp. 547-577, <raspoloživo na: http://psych.uw.edu.pl/mikk/4621%20METOD_COMM%20APS/dodatki/Our%20Word%20our%20selfes.pdf>, [pristupljeno 10.04.2015.].

Petz, B., (2004), Osnove statističke metode za nematematičare, V. izdanje, Jastrebarsko: Naklada Slap.

Poslovna Hrvatska, < www.poslovna.hr>, [pristupljeno 10.06.2013]

Potter, W. J. & Levine-Donnerstein, D., (1999), Rethinking validity and reliability in content analysis, [Online], pp. 258-284, <raspoloživo na: http://www.academia.edu/download/45649201/Rethinking_validity_and_reliability_in_content_analysis.pdf>, [pristupljeno 07.03.2015.].

Rafaeli, S., (1988), Interactivity: From new media to communication, Sage Annual Review of Communication Research: Advancing Communication Science, [Online], 16, pp. 110-134, Sage: Beverly Hills, CA, <raspoloživo na: http://gsb.haifa.ac.il/~sheizaf/interactivity/Interactivity_Rafaeli.pdf>, [pristupljeno 08.04.2014.].

Richardson, J. E. & Stanyer, J., (2011), Reader opinion in the digital age: Tabloid and broadsheet newspaper websites and the exercise of political voice, *Journalism, [Online], 12 (8),* <raspoloživo na: https://www.researchgate.net/profile/James_Stanyer/publication/239775322_Reader_opinion_in_the_digital_age_Tabloid_and_broadsheet_newspaper_websites_and_the_exercise_of_political_voice/links/55ae22c808aed9b7dcdb7327.pdf>, [pristupljeno 12.03.2015.].

Robinson, S. & DeShano, C., (2011), „Anyone can know": citizen journalism and the interpretive community of the mainstream press, Journalism, [Online], 12(8), pp. 963–982, <raspoloživo na: http://journals.sagepub.com/doi/pdf/10.1177/1464884911415973>, [pristupljeno 15.10.2016.].

Ruiz, C. et al., (2011), Public sphere 2.0? The democratic qualities of citizen debates in online newspapers, *The International Journal of Press/Politics, [Online], 16 (4),* pp. 463-487, <raspoloživo na: http://sites.coloradocollege.edu/wp-content/blogs.dir/247/files/2013/10/RuizDomingoIJPP.pdf>, [pristupljeno 18.04.2015.].

Ryan, K. J. & Natalie, E.J., (2001), Fusing horizons: Standpoint hermeneutics and invitational rhetoric, *Rhetoric Society Quarterly, [Online], 31 (2), pp.* 69-90, <raspoloživo na: http://libres.uncg.edu/ir/uncg/f/e_natalle_fusing_2001.pdf>, [pristupljeno 26.05.2014.].

Sahoo, N., Krishnan, R.& Faloutsos, C., (2008), Socio-temporal analysis of conversations in intra-organizational blogs, *Workshop on Information Technologies and Systems*, [Online], <raspoloživo na: http://people.bu.edu/nachi/blogtensor.pdf>, [pristupljeno 20.05.2014.].

Seawright, J. & Gerring, J., (2008), Case selection techniques in case study research a menu of qualitative and quantitative options, Political Research Quarterly, [Online], 61 (2), pp. 294-308, <raspoloživo na: http://www.academia.edu/download/30725636/Seawright_Gerring_2008_Case_Selection.pdf>, [pristupljeno 11.05.2014.].

Shemwell, J.T. & Furtak, E. M., (2010), Science classroom discussion as scientific argumentation: A study of conceptually rich (and poor) student talk, *Educational Assessment,* [Online], 15 (3), pp. 222 – 250, <raspoloživo na: https://www.researchgate.net/profile/Jonathan_Shemwell/publication/232875905_Science_Classroom_Discussion_as_Scientific_Argumentation_A_Study_of_Conceptually_Rich_and_Poor_Student_Talk/links/556e135408aec2268308c216.pdf>, [pristupljeno 26.06.2015.].

Shmueli, E. et al., (2012), Care to comment?: recommendations for commenting on news stories, Proceedings of the 21st international conference on World Wide Web, [Online], ACM, <raspoloživo na: http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.232.6961&rep=rep1&type=pdf>, [pristupljeno 21.06.2015.].

Slobodna Dalmacija, < www.slobodnadalmacija.hr>, [pristupljeno 16.06.2013]

Smith, C.S., (2003), *Modes of discourse: The local structure of texts*, [Online], Cambridge: Cambridge University Press, <raspoloživo na: http://www.sil.org/system/files/reapdata/12/10/31/121031206669929235872197281143754750 79/SILEBR_2004_013.pdf>, [pristupljeno 02.05.2014.].

Split: Konačni službeni rezultati izbora za gradonačelnika - 19. svibnja 2013, (2013), [Online], Zagreb: Državno izborno povjerenstvo, <raspoloživo na: http://www.izbori.hr/2013Lokalni/rezult/krug-1/r_17_17_4090_000.html?t=1487366923155>, [pristupljeno 08.06.2013.].

Stromer-Galley, J., (2007), Measuring deliberation's content: A coding scheme. *Journal of public deliberation* 3 (1), <raspoloživo na: http://www.publicdeliberation.net/cgi/viewcontent.cgi?article=1049&context=jpd>, [pristupljeno 12.05.2014.].

Sunstein, C. R., (2007), The Polarization of Extremes, The Chronicle Review, [Online], Dec 14, <raspoloživo na: http://www.law.uchicago.edu/news/sunstein-internet-and-political-polarization >, [pristupljeno 03.05.2014.].

Tanta, I., (2007), Oblikovanje mnijenja ili nužnost manipulacije, MEDIANALI-znanstveni časopis za medije, novinarstvo, masovno komuniciranje, odnose s javnostima i kulturu društva, [Online], 1 (2), pp. 13-32, <raspoloživo na: http://hrcak.srce.hr/file/65046>, [pristupljeno 08.10.2014.].

Thomas, G., (2011), A typology for the case study in social science following a review of definition, discourse, and structure, Qualitative inquiry, [Online], 17 (6), pp. 511-521, <raspoloživo na: http://www.besafe-project.net/files/DOWNLOAD2/Thomas_2011_typology%20for%20the%20case%20study%20in%20social%20science.pdf>, [pristupljeno 11.03.2014.].

Thurman, N. & Hermida, A., (2010), Gotcha: How newsroom norms are shaping participatory journalism online, Tunney, S. & Monaghan, G. (Eds.), Web Journalism: A New Form of Citizenship?, [Online], pp. 46-62, Eastbourne, UK: Sussex Academic Press, <raspoloživo na: http://openaccess.city.ac.uk/179/2/thurman_hermida_gotcha.pdf>, [pristupljeno 17.10.2014.].

T-portal, < www.tportal.hr>, [pristupljeno 14.06.2013]

Tuchman, G., (2008), Blogs and News Processes: Net Neutrality and Digital Inequality Gaye Tuchman and Stephen Ostertag, *Participation and Media Production: Critical Reflections on Content Creation*, [Online], <raspoloživo na: https://www.researchgate.net/profile/Stephen_Ostertag/publication/280300714_Blogs_and_News_Processes_Net_Neutrality_and_Digital_Inequality/links/55b0282008ae11d31039ada8.pdf>, [pristupljeno 15.03.2014.].

Tumitan, D. & Becker, K., (2013), Tracking Sentiment Evolution on User-Generated Content: A Case Study on the Brazilian Political Scene, *SBBD (Short Papers)*, [Online], <raspoloživo na: https://pdfs.semanticscholar.org/0d7b/5599aced755c02764711c49a1c43791fb654.pdf>, [pristupljeno 13.06.2015.].

Udovičić, M. et al., (2007), Što treba znati kada izračunavamo koeficijent korelacije?, Biochemia Medica, [Online], 17 (1), <raspoloživo na: http://www.biochemia-medica.com/content/s-treba-znati-kada-izracunavamo-koeficijent-korelacije>, [pristupljeno 08.10.2014.].

Vobič, I.& Dahlgren, P., (2013), Reconsidering Participatory Journalism in the Internet Age, Medijska istraživanja, [Online], 19 (2), pp. 9-30, <raspoloživo na: http://hrcak.srce.hr/file/165840>, [pristupljeno 5.10.2015.].

Vujević, M., (2006), Uvođenje u znanstveni rad u području društvenih znanosti, Zagreb: Školska Knjiga.

Weger, J. H. & Aakhus, M., (2003), Arguing in Internet chat rooms: Argumentative adaptations to chat room design and some consequences for public deliberation at a distance, Argumentation and advocacy, [Online], 40 (1), <raspoloživo na: http://www.academia.edu/download/39624685/Weger_JR__Aakhus__Weger_2003_Arguing_in_internet_chat_rooms_Argumentative_adaptations_to_chat_room_design_and_some_consequences_for_publ.pdf>, [pristupljeno 16.06.2015.].

Winkler, R., (2003), E-Democracy: Potentials and Constraints of Online Participation in the political public sphere, *E-Democracy: Technology, Law and Politics*, [Online], (174), pp. 5-14., <raspoloživo na: http://www.robert.krimmer.at/files/2003_prosser_krimmer_e-democracy/#page=11>, [pristupljeno 10.07.2014.].

Xu, T., Peng, Q. & Cheng, Y., (2012), Identifying the semantic orientation of terms using S-HAL for sentiment analysis, *Knowledge-Based Systems,* [Online], 35, pp. 279-289, <raspoloživo na: https://www.researchgate.net/profile/Tao_Xu11/publication/256558647_Identifying_the_semantic_orientation_of_terms_using_S-HAL_for_sentiment_analysis/links/02e7e5236d89a65fa2000000.pdf>, [pristupljeno 22.10.2014.].

Zaller, J., (2003), Coming to grips with VO Key's concept of latent opinion, *Electoral Democracy, [Online],* pp. 311-36, <raspoloživo na: https://www.econstor.eu/bitstream/10419/69237/1/735594988.pdf>, [pristupljeno 21.05.2014.].

Zbirna lista pravovaljanih kandidatura za izbor gradonačelnika grada Splita, (2013), [Online], Zagreb: Državno izborno povjerenstvo [online]. [citirano: 2015-06-15]. <raspoloživo na: http://www.izbori.hr/2013Lokalni/kandid/rjesenja/KandidRjeSlu_04_17_4090.pdf>, [pristupljeno 08.04.2013.].

Sažetak

U radu su primjenom metoda studije više slučaja i sadržajne analize istraživane odlike participativnog novinarstva i konverzacija građana novinara u razdoblju prije i za vrijeme predizborne kampanje za izbor splitskog gradonačelnika 2013. na pet hrvatskih novinskih portala: 24 sata, Indeks, T-portal, Slobodna Dalmacija i Dalmacija News, te je pomoću utvrđivanja semantičke orijentacije (SO) komentara provedena ručna analiza sentimenata izraženih prema kandidatima i njihovim odlikama: sposobnost, pristojnost, odgovornost, moralnost, izgled, domoljublje i kriminalnost. Tijekom analize izrađen je rječnik s 4913 izraza i riječi koje izražavaju sentimente prema političarima i njihovim odlikama. Na temelju strukture 604 konverzacije i analize 15 715 komentara utvrđeni su niska argumentiranost i niska interaktivnost konverzacije, zbog čega je zaključeno da je konverzacija građana novinara na istraživanim portalima imala nisku razinu javne rasprave. Građani su novinari na svim istraživanim portalima jedni prema drugima i prema kandidatima izražavali pretežito negativne sentimente, osim u slučaju Marijane Puljak. Usporedba raspodjele rezultata za SO komentara pokazala je da građani novinari na istraživanim portalima ne pripadaju istoj populaciji. Novinski su se portali međusobno razlikovali i prema: broju objavljenih članaka o kandidatima, broju komentara o kandidatima i broju građana novinara koji su sudjelovali u konverzaciji. Na svim je portalima izražena dominacija novinskih članaka i broja komentara građana novinara o Željku Kerumu, te je na gotovo svim portalima uočeno da je u kategoriji Domoljublje najlošije bio ocijenjen SDP-ov kandidat Ivo Baldasar, a u kategoriji Kriminalnost HDZ-ov kandidat Vjekoslav Ivanišević. Na dva novinska portala koji su objavili novinske članke o svim kandidatima (Slobodna Dalmacija i Dalmacija News) utvrđena je povezanost izbornih rezultata s brojem objavljenih članaka o kandidatu, brojem komentara o kandidatu, brojem građana novinara koji su komentirali kandidata i brojem građana novinara koji su prema kandidatu bili pozitivno ili negativno orijentirani.

Rezultati ovog istraživanja u slučajevima pet hrvatskih novinskih portala pokazali su da postoji povezanost između participativnog novinarstva i izbornih rezultata te da je konverzacija građana novinara bila daleko od ideala javne rasprave kakvu opisuje Habermas (1996).

Ključne riječi: javna rasprava; novinski portali; participativno novinarstvo; semantička orijentacija

Summary

Using the methods cross-case analysis and content analysis this dissertation investigated the characteristics of participatory journalism and conversation between citizen journalists in the period before and during the election campaign for the election of the mayor of Split in 2013. in five croatian news portal: 24 sata, Index, T-portal, Slobodna Dalmacija and Dalmacija News, and by determining the semantic orientation (SO) of comments performed manual sentiment analysis, exploring sentiments expressed toward candidates and their qualities: competence, politeness, responsibility, morality, appearance, patriotism and criminality. During the analysis dictionary was built with 4 913 words and phrases that express the sentiments toward politicians and their characteristics. Based on the structure of 604 conversations and analysis of 15 715 comments low argumentation and low interactivity of conversation were found, a it is concluded that the conversation between citizen journalists in the studied portals had a low level of public deliberation. Citizens journalists at all investigated portals expressed predominantly negative sentiments toward each other and toward the candidates, except in the case of Marijana Puljak. Comparison of the distribution of results for SO of comments showed that citizen journalists in the studied portals do not belong to the same population. News portals are also different from each other in relation to: the number of articles about the candidates, the number of comments on the candidates and the number of citizen journalists who participated in the conversation. Domination of newspaper articles and the number of comments on Željko Kerum is common for all the portals, and on almost all portals are observed that in the category Patriotism SDP candidate Ivo Baldasar got lowest score, and in the category Criminality HDZ candidate Vjekoslav Ivaniševic got lowest score. On two news portals that have published newspaper articles about all the candidates (Slobodna Dalmacija and Dalmatia News) correlation was found between election results and number of published articles about the candidates, the number of comments on the candidates, the number of citizen journalists who commented on the candidates and the number of citizen journalists positively or negatively oriented toward candidates.

The results of this research in the cases of five croatian news portals showed that there is a relationship between participatory journalism and election results, and that conversation between citizen journalists is still far from the ideal of public deliberation that describes Habermas (1996).

Key words: public deliberation; news portals; participatory journalism; semantic orientation

Životopis

Danira Matijaca, dipl. bibl., nakon završetka Matematičko-informatičkog obrazovnog centra (MIOC) u Splitu, upisala je 1990. Fakultet prirodoslovno-matematičkih znanosti u Splitu, studij fizike i politehnike. Diplomirala je 1996. na temu „Uporaba interneta u nastavi fizike“ i stekla zvanje profesora fizike i politehnike. 2002. upisala je izvanredni dvogodišnji studij knjižničarstva na Filozofskom fakultetu u Osijeku, na dislociranom studiju u Zadru. Nakon tri godine, 2005. diplomirala je na temu „ Istraživanje potreba korisnika Gradske knjižnice Marko Marulić u Splitu“ pod mentorstvom prof. dr. sc. Srećka Jelušića. Doktorski studij Društvo znanja i prijenos informacija na Sveučilištu u Zadru upisala je 2011. Jednu godinu radila je kao novinarka HTV-a u Splitu, zatim kao profesorica fizike u II. jezičnoj gimnaziji u Splitu, te nastavnica fizike, tehničke kulture i informatike u nekoliko osnovnih škola. Od 2003. zaposlena je kao novinarka u Tiskovnom uredu Splitsko-makarske nadbiskupije, gdje radi kao voditeljica i urednica televizijske vjerske emisije.