DETERMINANTE I UTJECAJ POVJERENJA U KORISNIČKE OSVRTE U KONTEKSTU ONLINE TRGOVINE

Ožić Paić, Sanja

Master's thesis / Diplomski rad

2018

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Split, Faculty of economics Split / Sveučilište u Splitu, Ekonomski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:124:062950

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-25**

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

zir.nsk.hr

UNIVERSITY OF SPLIT

dabar

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U SPLITU

EKONOMSKI FAKULTET

DIPLOMSKI RAD

DETERMINANTE I UTJECAJ POVJERENJA U KORISNIČKE OSVRTE U KONTEKSTU ONLINE TRGOVINE

Mentor:

Doc.dr.sc. Goran Dedić

Studentica:

Ožić Paić Sanja

Split, rujan, 2018

Sadržaj

1. Uvod 1

1.1. Predmet i problem istraživanja 1

1.2. Svrha i ciljevi istraživanja 7

1.3. Metode istraživanja 8

1.5. Struktura diplomskog rada 10

2. Digitalni marketing 11

2.1. Uvodna razmatranja 11

2.2. Razvoj digitalnog marketinga 12

2.3. Strategija digitalnog marketinga 13

2.4. Pojavni oblici digitalnog marketinga 16

2.4.1. Marketing na tražilicama 17

2.4.2. Prikazivački marketing 18

2.4.3. E-mail marketing 19

2.4.4. Marketing suradnje 19

2.4.5. Društveni marketing 20

2.4.6. Mobilni marketing 20

2.4.7. Marketing prikupljanja kontakata 21

2.4.8. Marketing sadržaja 21

2.4.9. Sponzorstva 21

2.4.10. Nativno oglašavanje 22

3. E – trgovina 23

3.1. Pregled razvoja e-trgovine 25

3.1.1. Period izuma – 1995. do 2000. 26

3.1.2. Period konsolidacije – 2001. do 2006. 27

3.1.3. Period ponovnog izuma od 2007. do danas 28

3.2. Karakteristike e – trgovine 28

3.3. Modaliteti e – trgovine 31

3.4. Odnos offline i online trgovine 32

3.5. Proces online kupovine – aspekt korisnika i prepreke 34

3.6. Platforme za online kupovinu 36

4. Usmena predaja 38

4.1. Zašto se ljudi uključuju u WoM 39

4.2. Odnos pozitivne i negativne usmene predaje 43

5. Korisnički osvrti 45

5.1. Karakteristike online korisničkih osvrta 46

5.2. Odnos potrošača i osvrta 50

5.3. Potencijalne poteškoće 51

5.4. Aktualni trendovi 52

6. Povjerenje 65

6.1. Teoretske odrednice **65**
6.2. Što prethodi povjerenju **67**
6.3. Povjerenje – mehanizmi djelovanja i tipologija **70**
6.3.1. Inicijalno povjerenje 70
6.3.2. Modeli povjerenja 71
6.4. Odnos offline i online povjerenja u kontekstu e trgovine **75**

7. Istraživanje **77**
7.1. Hipoteze istraživanja **77**
7.2. Metodologija istraživanja **78**
7.2.1. Rudarenje teksta i analiza sentimenta 78
7.2.2. Anketni upitnik 80
7.3. Analiza sentimenta **83**
7.3.1. Provođenje analize sentimenta 83
7.3.2. Rezultati analize sentimenta 86
7.4. Friedmanova ANOVA **90**
7.4.1. Friedmanova ANOVA za indekse percipirane vjerodostojnosti 90
7.4.2. Friedmanova ANOVA za pojedine tvrdnje percipirane vjerodostojnosti autora i osvrta 92
7.5. Faktorska analiza **96**
7.6. Regresijska analiza **99**
7.6.1. Dijagnostika modela 102
7.7. Klaster analiza **106**

8. Rasprava rezultata analize **110**

9. Ograničenja i implikacije istraživanja **112**
9.1. Ograničenja **112**
9.2. Implikacije rezultata istraživanja **113**

10. Naznake za buduća istraživanja **114**

11. Zaključak **115**

Sažetak **119**

Summary **120**

Izvori **121**

POPIS SLIKA I TABLICA **128**

Dodaci **130**

1. Uvod

1.1. Predmet i problem istraživanja

Neupitna je činjenica da je razvoj interneta doveo do značajnih promjena u svakodnevnom životu i poslovanju, a što je naročito postalo razvidno pojavom Web 2.0 tehnologija, koji je omogućio direktnu komunikaciju među korisnicima, pregled sadržaja na zahtjev, pristup informacijama na globalnoj razini i tako dalje, s tim da se sve funkcionalnosti i primjene stalno unapređuju. Ne tako davno, Utz i sur. (2012) su naveli nepovjerenje u online kupovinu zbog nepovjerenja u okolinu e – trgovine, iako se sve više kupovina obavlja putem weba, još je uvijek prisutan strah od negativnog iskustva. Razlog tomu je odmak od klasičnog iskustva kupovine na kojeg su potrošači navikli, a koji se ogleda u izostanku fizičkog kontakta s trgovcem i osobne komunikacije s prodavačem, nemogućnosti razgledavanja i izravnog iskušavanja opipljivih karakteristika proizvoda. Tako Utz i sur. (2009) navode kako problemi u domeni povjerenja između kupaca i prodavača u procesu online trgovine proizlaze iz njegove prirode – sudionici kupoprodajnog procesa se međusobno ne poznaju, žive na različitim lokacijama te u većini slučajeva u interakciju ulaze zbog jedne transakcije. McKnight i sur. (2002) razlikuju nekoliko dimenzija povjerenja u sferi e – trgovine: vjerovanje da će prodavač ispuniti svoje obveze, vjerovanje da prodavač koristi podatke o kupcima u skladu s pravilima etičnosti te percepcija o samom Internetu, odnosno o njegovoj tehnološkoj pouzdanosti i sigurnosti. Navedene dimenzije povjerenja su međusobno neovisne te nisu isključive, međutim zajedno formiraju ukupno povjerenje. Također, kupci nisu u mogućnosti dodirnuti proizvod, boje mogu izgledati drugačije ovisno o pretraživaču ili ekranu, razmjena se ne odvija u istom vremenskom trenutku - kupac prvo prebaci sredstva, tj. plaća pa prodavatelj potom šalje proizvod. Dodatno, otegotna okolnost je u tome što su ove transakcije potpomognute tehnologijom i kao takve podložne tehničkim pogreškama, prisutni su i rizici da proizvod neće biti poslan ili da će biti poslan kasnije od definiranog roka te da će biti lošije kvalitete (Utz i sur., 2012). Sve navedeno vodi do pitanja je li povjerenje u online kontekstu važno? Ako jest, koje su implikacije? Značaj povjerenja proizlazi iz njegove uloge u nadilaženju percipiranog rizika i smanjenju nesigurnosti, ali i poticanju potrošača da se upuste u „ponašanja temeljena na povjerenju“ (*eng. trust related behaviour*) s online trgovcima (McKnight i sur., 2002). Sam proces online kupovine podrazumijeva da potrošači trebaju dati svoje osobne podatke, od adrese do broja kartice, kako bi do kupovine uopće došlo, a

nepovjerenje naročito izraženo kada se po prvi put kupuje od nekog online trgovca. McKnight i sur. (2002) u ovom slučaju kao posebno značajan tip povjerenja navode *inicijalno povjerenje* koje se odnosi na povjerenje u nepoznati subjekt, odnosno na odnos u kojem sudionici još uvijek nisu bili u međusobnom kontaktu niti su se razvile veze među njima.

Razvidno je kako je jedan od glavnih problema u uspostavljanju odnosa u kontekstu e – trgovine povjerenje, kojeg Mayer i sur. (1995) definiraju kao *„spremnost pojedinca na ranjivost zbog aktivnosti drugih, temeljenu na očekivanju da će druga strana poduzeti aktivnosti od važnosti za pojedinca, bez obzira na mogućnost praćenja ili kontroliranja aktivnosti druge strane.“*. Kako bi smanjili percipirani rizik i nesigurnost prilikom odabira proizvoda i prodavača, potencijalni kupci tijekom donošenja odluke o kupnji poduzimaju različite postupke, raspravljene u nastavku. Tako, u spomenutom kontekstu usmena predaja ili propaganda od usta do usta (eng. Word of Mouth, dalje WoM) ima posebno značajno mjesto, jer je, kako Akyüz (2013) navodi, primarni utjecajni faktor na 20 do 50% kupovnih odluka. Tradicionalni WoM se definira kao „*usmena komunikacija između dvije ili više osoba, koja podrazumijeva razmjenu informacija o brendu, proizvodu ili usluzi, na ne–komercijalnoj bazi*“ (Delozier i Woodside, 1976, citirani u MacKinnon, 2012). Iz spomenute definicije proizlazi da se usmena predaja o proizvodu, bila ona pozitivna ili negativna, prenosi među pojedincima među kojima postoje uspostavljeni odnosi, tj. koji međusobno komuniciraju te da poduzeće nad tim nema kontrolu, utjecaj ni mogućnosti mjerenja. Razlog važnosti koju potencijalni kupci pridaju WoM–u autori nalaze u činjenici da takve informacije dolaze od samih potrošača, a ne od poduzeća te je kao takvu smatraju vjerodostojnijom u formiranju očekivanja i donošenja kupovne odluke. Kada se u obzir uzme i prethodno navedeno o utjecaju WoM–a na kupovnu namjeru, očito je da se radi o konceptu od izuzetnog značaja za ugled marke i profitabilnost poduzeća.

Propulzijom Interneta, naročito Web 2.0 tehnologije, omogućeno je stvaranje novog tipa WoM–a – elektronska usmena predaja (eng. Electronic Word of Mouth, dalje eWoM), koji podrazumijeva društvenu interakciju među korisnicima interneta u smislu kreiranja i dijeljenja sadržaja, mišljenja i preporuka (Akyüz, 2013), a kroz omogućavanje kreiranja online područja, odnosno virtualnih javnosti koja pružaju mogućnost javne međuosobne komunikacije imaju društveni, organizacijski i ekonomski značaj (Jones i sur., 2004). Virtualne javnosti su definirana, računalno potpomognuta mjesta, kao što su e–mail liste, chatovi, zajednice na društvenim mrežama i sl., a koje omogućavaju širok raspon interakcija među sudionicima (Jones i sur., 2004).

eWoM Henning–Thurau i sur. (2004) definiraju kao „*bilo kakve pozitivne ili negativne tvrdnje nastale od strane potencijalnih, trenutnih ili bivših potrošača o proizvodu ili poduzeću, a koje su dostupne velikom broju pojedinaca i/ili institucija putem interneta*“. Web 2.0 i aplikacije razvijene u sklopu istog doveli su do transformacije masovne komunikacije od jednosmjernog do dvosmjernog komunikacijskog sustava, zahvaljujući čemu čak i prosječni korisnici interneta mogu jednostavno kreirati i proširiti medijski sadržaj (Wang i Rodgers, 2010), a autori navode dva tipa takvog sadržaja: sadržaj kreiran od strane korisnika (eng. *User Generated Content*, dalje UGC) i sadržaj kreiran od strane potrošača (eng. *Consumer Generated Content*, dalje CGC).

U tom kontekstu različiti autori drugačije klasificiraju eWoM. MacKinnon (2012) smatra kako je eWoM zapravo tip UGC – a, obzirom da podržava sve definirane karakteristike spomenutog, a to su: 1) sadržaj koji je javno dostupan putem interneta; 2) sadržaj koji podrazumijeva određenu razinu kreativnog napora; 3) sadržaj koji je stvoren van okvira profesionalnih praksi i rutina. Svjesni mogućnosti novih mrežnih tehnologija te mogućnosti uključivanja u svojevrsni dijalog putem sadržaja, kao i činjenice da je eWoM postao, kako Doh i Hwang (2009) navode važan čimbenik u donošenju kupovne odluke, brojna poduzeća se uključuju u online sferu komunikacija, tj. društvenih medija i mreža koje karakterizira korisnik – prema – korisniku (eng. peer to peer) komunikacija (Wang i Rodgers, 2010). Autori dalje navode kako je eWoM praktična primjena CGC–a u sklopu digitalnog oglašivačkog miksa, a potvrdu tome pronalaze i u definiciji CGC – a, kao sadržaja stvorenog i objavljenog od strane svakodnevnih korisnika, a ne medija ili komunikacijskih profesionalaca te se kao takav uklapa u definiciju eWoM – a. Dostupne su i druge klasifikacije eWoM-a pa tako Wang i Rodgers (2010) razlikuju dva tipa, prvi koji se javlja u online sustavima povratnih informacija i stranicama namijenjenima osvrtima i kritikama, a drugi koji se javlja u prostorima namijenjenim raspravama, online zajednicama i društvenim mrežama. Također, brojni su autori identificirali nekoliko aspekata koji definiraju eWOM, a osnovni i najznačajniji su *informacijski*, npr. potrošački osvrti, i *emocionalni*, npr. dijeljenje mišljenja i komentara s prijateljima (Dillard i Nabi, 2006; Evans i sur., 2001; Fong i Burton, 2006; Lieberman i Goldstein, 2005;citirani u Wang i Rodgers, 2010).

Hennig-Thurau i sur., (2004) nadalje smatraju kako se eWOM komunikacija može javiti u različitim oblicima – platforme za izražavanje mišljenja, forumima, društvenim mrežama, blogovima isl. Također, identificirali su 11 motiva potrošača za uključivanje u eWOM komunikaciju: briga za druge potrošače, želja za pomoći poduzeću, dobivanje društvenih koristi,

iskazivanje moći nad poduzećem, postkupovno traženje savjeta, samo – unapređenje, ekonomske koristi, pogodnost u traženju ispravka, nada da će platforma biti moderator, ekspresija pozitivnih osjećaja te izražavanje negativnih osjećaja.

Usprkos različitim klasifikacijama eWoM–a, moguće je identificirati karakteristike zajedničke svima, između ostalih: ulaganje truda, vremena i energije od strane korisnika/potrošača, a od čega potrošači pa i poduzeća imaju određenih koristi (Ghose i Ipeirotis, 2011). U tom kontekstu autori smatraju kako značaj eWoM-a leži u tome „tko" kaže „što" i „kako" je to izrečeno, a što potencijalni kupci dalje koriste kako bi saznali više o proizvodu ili marki, njegovim pozitivnim ili negativnim karakteristikama (Doh i Hwang, 2009).

Dakle, eWoM, kao korisničko kreiranje i širenje mišljenja o proizvodu služi kako bi se potencijalne potrošače potaklo na ili obeshrabrilo od kupnje proizvoda (Sen i Lerman, 2007), obzirom na to radi li se o pozitivnim ili negativnim komentarima. Istraživanja u čijem je fokusu bio odnos pozitivnih i negativnih osvrta te utjecaja istih na potrošače pokazala su kako se više pažnje pridaje negativnim komentarima (Sen i Lerman, 2007), a autori obrazloženje nalaze u *efektu negativnosti* koji govori kako je pojedinčevo društveno okruženje pretežito pozitivno te se stoga negativni signali više uočavaju. Ipak, pojedina su istraživanja pokazala kako određeni udio negativnih komentara zapravo doprinosi prodaji (Berger i sur, 2010, citirano u Utz i sur., 2012). Obrazloženje tomu Utz i sur. (2012) nalaze dijelom u efektu negativnosti - zbog urođene predispozicije traženja negativnih signala takvi će komentari biti zamijećeni, a dijelom u tome što komentari koji uključuju pozitivne i negativne aspekte proizvoda ili usluge doprinose vjerodostojnosti osvrta, osobe koja je napisala osvrt te samog brenda. Dakle, moguće je zaključiti kako su ponašanje u komunikaciji i kupovno ponašanje kompleksni i bitni bihevioralni aspekti za profitabilnost proizvoda i usluga te su pod velikim utjecajem čitanja online osvrta (Hennig-Thurau i Walsh, 2003). Izgledno je da će potrošači prilagoditi svoje kupovno ponašanje nakon čitanja pozitivnog ili negativnog komentara i to u online i klasičnim prodajnim kanalima. Hennig-Thurau i Walsh (2003) smatraju kako sa stajališta poduzeća, iskazivanje mišljenja potrošača istovremeno predstavljaju prednost i rizik. Prednosti se ogledaju u mogućnosti praćenja usmene predaje te u skladu s tim i prilagodbu vlastite strategije komunikacije, moguće je uočiti i potencijalne slabe točke u smislu proizvoda i usluga te iste unaprijediti. S druge strane, rizici se nalaze u brzom širenju negativne usmene predaje van kontrole poduzeća, koja za razliku od tradicionalne usmene predaje ne nestaje, već ostaje dostupna svim potencijalnim potrošačima.

S aspekta potrošača, uz brojne prednosti dostupnosti korisnih informacija javljaju se i problemi koji proizlaze iz količine i dostupnosti informacija, što je potaklo i određene brige o kredibilitetu izvora informacija, kvaliteti i istinitosti (Metzger i Flanagin, 2013).Naime, upitnost vjerodostojnosti izvora eWoM – a proizlazi iz njihove anonimnosti i motivacije odluke da se uključe u kreiranje osvrta (Sen i Lerman, 2007). Iz tog razloga, korisnici u potrazi za korisnim informacijama koje će im olakšati odluku često moraju voditi računa i o pronalasku „pravih" informacija, onima kojima mogu vjerovati. Metzger i Flanagin, (2013) smatraju kako se smanjenje nesigurnosti vezane uz informacije često temelji na osobnom znanju, pronalasku posrednih informacija koje će potvrditi kredibilitet izvora informacija te oslanjanju na tradicionalne posrednike kao što su stručnjaci i lideri mišljenja.

Uz sve prednosti, veću dostupnost i transparentnost informacija, dolazi do zagušenja kanala do te mjere da sudionici ne mogu adekvatno procesirati ni odgovoriti (Jones i sur, 2004) te nisu u mogućnosti procijeniti koje su recenzije zaista korisne (Victor i sur., 2009). Navedeno je bio poticaj razvoju sustava za procjenu vjerodostojnosti i korisnosti pojedinih osvrta, koji prikupljaju, procjenjuju značaj i automatski distribuiraju povratne informacije o prethodnim ponašanjima sudionika (Resnick i sur., 2001, citirano u Utz 2009). Jedan od primjera je izračun *globalne ocjene* (Victor i sur., 2009) – „x od y ljudi smatra ovaj osvrt korisnim", a kojeg koristi Amazon. Međutim, kako autori navode, problem ovakve ocjene je u tome što nešto što je korisno jednoj osobi, ne mora nužno biti korisno i drugoj. Epinions, s druge strane uključuje rangiranje korisnosti osvrta ocjenama od 1 do 5, što prema Victor i sur. (2009) daje bolju procjenu, međutim napominju problem *kontroverznih osvrta,* onih s krajnjim vrijednostima koji u izračunatoj prosječnoj ocjeni mogu biti uzrokom velikih devijacija. eBay uspješno implementira napredniji sustav, a putem kojeg su korisnicima dostupne povratne informacije o svim sudionicima s kojima će potencijalno ući u odnos. Naime, eBay kupcima i prodavačima nudi mogućnost međusobnog ocjenjivanja kroz pružanje pozitivnih, negativnih i neutralnih povratnih informacija, a skupna ocjena, u apsolutnom i relativnom izrazu, je vidljiva na njihovim profilima (Utz, 2009).

Razvidno je kako mnogobrojni čimbenici utječu na formiranje povjerenja i percipirane vjerodostojnosti osvrta u kontekstu online trgovine. Mayer i sur. (1995) navode tri komponente percipirane vjerodostojnosti: benevolencija, integritet i mogućnost. Benevolencija opisuje razmjer u kojem je pojedinac voljan vjerovati drugima, integritet označava pridržavanje seta principa koje pojedinac smatra važnima dok mogućnost znači da partner u interakciji posjeduje potrebne vještine

i sposobnosti za sudjelovanje u interakciji. Utz i sur. (2012) smatraju kako se povjerenje u online kontekstu formira temeljem utjecaja eWoM – a, reputacije online trgovine, koja je definirana brzom i točnom dostavom, umješnim upravljanjem pritužbama te kvaliteti samog proizvoda, te urođenoj sklonosti povjerenju. Drugi su autori razmatrali i ulogu pojedinčeve podložnosti utjecaju drugih kao determinante povjerenja i utjecaja istog na donošenje kupovne odluke (Park i sur., 2011; Akyüz, 2013), pri čemu su doneseni zaključci kako osobe podložne utjecaju drugih imaju veću vjerojatnost širenja eWoM – a, ali i veći stupanj vjerovanja te temeljem istog donošenja odluke. McKnight i sur. (2002) razmatraju više komponenti i tipova povjerenja, počevši od institucijskog kao vjerovanja da će potrebni strukturni uvjeti biti zadovoljeni kako bi se postigao uspješni ishod u online trgovini, te urođene sklonosti, dispoziciji povjerenju koju definiraju kao mjeru u kojoj osoba iskazuje tendenciju ka spremnosti na ovisnost o drugima kroz širok spektar situacija i osoba.

Pitanje povjerenja te njegove uloge u razmatranju i procesiranju online recenzije te njihova međuodnosa i utjecaja na donošenje kupovne odluke u kontekstu online trgovine je kompleksno te uključuje razmatranje niza faktora. Smisleno je pretpostaviti kako će se različite kombinacije čimbenika raspravljenih u prethodnoj diskusiji, koristiti i utjecati na kupovnu odluku proizvoda i usluga različitih karakteristika i primjene, a što su potvrdila i istraživanja (Doh i Hwang, 2009; Sen i Lerman, 2007; Utz i sur.,2012). Kao što je razvoj Internet i pratećih Web 2.0 servisa, utjecao na sve aspekte života i djelovanja pojedinaca, tako je - zbog svoje pogodnosti, globalne dostupnosti proizvoda te povoljnosti, online trgovine našla svoje mjesto u svakodnevnom životu, a trgovci su na rastuće zahtjeve potrošača odgovorili širokom ponudom i mogućnostima. Rastuća ponuda podrazumijeva otežanu procjenu alternativa te traženje kvalitetnih informacija koji će istu potpomoći. Zahvaljujući skupu tehnoloških rješenja objedinjenih pod konceptom Weba 2.0, korisnici su u mogućnosti ostavljati svoje recenzije, osvrte na proizvode s kojima su se susreli, odnosno podijeliti svoja iskustva s drugima, a što potencijalnim kupcima predstavlja vjerodostojniji izvor informacija od samog poduzeća. Vodeći se prethodno navedenim u ovom će se radu ispitati percipirana korisnost i vjerodostojnost recenzija s obzirom na njihovo oblikovanje, tj. korištenje pozitivnih i negativnih izraza kroz različite kategorije proizvoda. Način na koji su predstavljeni proizvod i recenzije, tj. strukturno oblikovanje stranice te utjecaj na povjerenje prema proizvodu/trgovcu i osvrtu, a posljedično i na kupovnu odluku će također biti istraženi kako bi se utvrdili mehanizmi njihova djelovanja. Bitan čimbenik koji utječe na prethodno razrađena pitanja je i urođena dispozicija povjerenju, značaj koje u kontekstu formiranja online povjerenja i

donošenja kupovne odluke je sastavni, nezaobilazni dio istraživanja, kao i mogućnost segmentiranja pojedinaca prema istoj.

1.2. Svrha i ciljevi istraživanja

Primarni fokus ovog rada je istražiti utjecaj korisničkih osvrta te povjerenja u iste u kontekstu online trgovine na percipiranu vjerodostojnost i kupovnu namjeru proizvoda/brendova na koje se odnose. Korisnički su osvrti odabrani kao vid elektronskog WoM – a koji ima izuzetan značaj prilikom donošenja kupovne odluke, obzirom da se direktno vežu na konkretne proizvode te predstavljaju direktnu nadogradnju klasičnog marketinškog pojma usmene predaje. U usporedbi s usmenom predajom, eWoM ima nekoliko istaknutih razlika, a većina ih proizlazi iz odnosa sudionika u komunikaciji i okruženja u kojem se prenose.

Kako je prethodno razrađeno, zbog činjenice da praktički svi korisnici interneta imaju mogućnost ostavljanja osvrta prisutno je mnoštvo informacija, koji su stilski i sadržajno različiti te se postavlja pitanje koje su to *determinante formiranja povjerenja i percipirane vjerodostojnosti osvrta te koji je njihov utjecaj na kupovnu namjeru*. Stoga je potrebno, kako bi se ostvarila svrha istraživanja, identificirati, istražiti i analizirati spomenute teoretske konstrukte usmene predaje, eWoM – a te povjerenja, zajedno s pripadajućim zaključcima postojećih istraživanja, a koji su temelj postavljanja empirijskog dijela rada.

1.3. Metode istraživanja

Rad se sastoji od dva dijela, teoretskog i empirijskog, pri čemu svaki zahtijeva primjenu određenih metoda kako bi se nalasci mogli valjano i pouzdano interpretirati te u konačnici, donositi relevantni zaključci.

Prvo će biti predstavljeni teoretski konstrukti u vidu pregleda i razrade literature te postojećih istraživanja, a u svrhu analiziranja istih i upoznavanja materije. Temelj postizanja navedenog je pretraživanje dostupnih baza postojećih članaka, istraživanja i knjiga, posebice Google Scholara, kroz tzv. istraživanje za stolom. Cilj je analize teorijskih koncepata upoznati determinante povjerenja i njihove međuodnose u mrežnom okruženju te mehanizme njihova djelovanja na korisnike. Temeljitim pregledom dostupnih istraživanja i teorija, odnosno sekundarnih podataka, nastoji se upoznati predmet istraživanja, postići shvaćanje problema istraživanja kako bi predstojeći empirijski dio bio utemeljen na valjanim teorijskim uporištima.

Prilikom izrade ovog rada voditi će se sljedećim metodama, prema Zelenika (1988):

Metoda indukcije – primjena takvog načina zaključivanja kojim se temeljem pojedinačnih ili posebnih činjenica dolazi do općenitih zaključaka;

Metoda dedukcije – primjena principa zaključivanja koji podrazumijeva deriviranje pojedinačnih zaključaka iz općenitih, odnosno iz jedne ili više tvrdnji se iznosi neka nova tvrdnja;

Metoda analize – proces raščlanjivanja složenih misaonih tvorevina na jednostavnije sastavne dijelove i elemente te izučavanje svakog od njih;

Metoda sinteze – proces spajanja i povezivanja jednostavnijih misaonih tvorevina u složenije, odnosno formiranje smislene jedinstvene cjeline;

Metoda klasifikacije – može se promatrati kao proces određivanja mjesta jednog pojma u sustavu pojmova, odnosno podjela pojmova, predmeta, sudova i sl.;

Metoda komparacije – uspoređivanje istih ili srodnih činjenica, tj. utvrđivanje njihovih sličnosti ili različitosti te intenziteta istih,

Metoda deskripcije – proces opisivanja činjenica, procesa i predmeta te empirijsko potvrđivanje njihovih odnosa, ali bez znanstvenog tumačenja;

Empirijski dio rada se može promatrati u nekoliko cjelina. Prvo će se provesti prikupljanje online recenzija od strane korisnika prema definiranim kriterijima. Potom će se metodom rudarenja teksta nastojati utvrditi semantička orijentacija istih te rudarenje mišljenja (analiza sentimenta)

kako bi se ispitala prva hipoteza, a koristeći adekvatne statističke tehnike unutar programskog rješenja RapidMiner.

Nadalje, biti će provedeno primarno istraživanje u vidu online anketnog upitnika nad namjernim uzorkom, zbog dostupnosti ispitanika, pri čemu će se nastojati postići reprezentativnost uzorka kroz definiranje kvota prema spolu i dobi. Anketni će upitnik biti strukturiran u više dijelova, prvim će se dijelom prikupiti demografski podaci, kako bis e upoznale karakteristike ispitanika u uzorku te formirale kvote. Narednim će se dijelovima upitnika ispitati stavovi i reakcije ispitanika na pojedine online osvrte te specifičnosti u kontekstu povjerenja u iste. Svrha anketnog upitnika je testiranje preostalih hipoteza odgovarajućim metodama statističke analize putem rješenja SPS

5. 1.4. Doprinos istraživanja

Kako je prethodno spomenuto, problematika povjerenja u online osvrte, konkretno determinante i sastavnice povjerenja u online kontekstu, kao i utjecaj istih tek nedavno počinje zadobivati pažnju istraživača na svjetskoj razini, dok pretraživanjem literature nije pronađen nijedan rad ovog ili sličnog tipa na hrvatskom jeziku.

Konkretni doprinos ovog rada je moguće promatrati s aspekta budućih znanstvenih marketinških istraživanja te s aspekta praktične primjene rezultata i zaključaka istraživanja. Sa stajališta budućih istraživanja, rezultati istraživanja u sklopu ovog rada će dati uvid u eventualne pomake u klasičnim pristupima povjerenju potrošača prema proizvodima i/ili markama koji su nastali svakodnevnom primjenom interneta. Također, nastojanje je skretanje pozornosti na značajne aspekte uzroka i ponašanja potrošača u novom okruženju, a koje nadilazi problematiku samog rada.

Praktična primjena je u prezentiranju argumenata za primjenu konkretnih smjernica u budućem oblikovanju web stranica i njihovih dijelova namijenjenih potrošačima/korisnicima, u smislu na poticanje prilaganja vlastitih osvrta, lakšem pregledu postojećih u svrhu lakšeg donošenja odluke te dati spoznaju o elementima koji potiču povjerenje i načinu njihove eventualne primjene. Također, cilj je doprinijeti shvaćanju i unapređenju postupaka istraživanja tržišta za poslovne svrhe kroz prezentiranje mogućnosti korištenja podataka koje poduzeću – vlasniku web stranice, stoje na raspolaganju, ali ne postoji svijest o potencijalu njihove analize.

Doprinos se ogleda i u korištenju novih metoda istraživanja, rudarenja teksta i pripadajućih tehnika, koje su se počele razvijati u proteklom desetljeću te u sklopu kojih se gotovo svakodnevno

iznalaze nove mogućnosti. Njihov je potencijal primjene u sklopu marketinških istraživanja, bilo za znanstvene ili praktične svrhe, gotovo nemjerljiv, jer pružaju direktan uvid u um potrošača/korisnika. Ipak, upravo je navedeno i razlog određenoj razini skepticizma u primjeni metodologije rudarenja teksta, odnosno kvantifikaciji mišljenja, jer se individualni stilovi izražavanja razlikuju. Stoga interpretacija rezultata leži u sposobnosti i vještini istraživača u prikupljanju i pripremi podataka te smislenoj interpretaciji rezultata. Međutim, vrijednost ove metode je neupitna te je pitanje vremena kada će njena primjena postati pravilo, a naročito u kombinaciji s već klasičnim metodama.

1.5. Struktura diplomskog rada

Diplomski rad obrađuje nekoliko područja koja će biti razrađena kroz sljedeća poglavlja. *Uvodnim* se *dijelom* definiraju temeljne odrednice rada, a to su problem i predmet istraživanja, istraživačka pitanja, svrha i ciljevi istraživanja te metode i doprinos.

Kako bi se pojam korisničkih osvrta u mogao spoznati u svom prirodnom kontekstu biti će obrađena područja digitalnog marketinga te e-trgovina, a što su teme *drugog i trećeg poglavlja*. Nadalje je potrebno upoznati se s pojmom usmene predaje, njenih odrednica i utjecaja u svakodnevnom životu, čime se bavi *četvrto poglavlje*.

Petim se *poglavljem* obuhvaća pojam korisničkih osvrta, odnosno konkretizaciju elektronske usmene predaje, njenu usporedbu s tradicionalnom usmenom predajom te razvojem i pojavnim oblicima. *Šesto poglavlje* se bavi povjerenjem kao centralnim pojmom istraživanja te će biti predstavljen pregled dostupnih teorija.

Sedmim se *poglavljem* daje uvid u samo istraživanje, korištenih metoda i tehnika istraživanja, uzorka i uzorkovanja te konačnih rezultata istraživanja.

Posljednja se poglavlja se bave praktičnim zaključcima rezultata istraživanja te njihovim znanstvenim i praktičnim implikacijama. Također, dana su ograničenja i poteškoće u provođenju istraživanja i naznake za poboljšanja i proširenja u budućim istraživanjima.

2. Digitalni marketing

2.1. Uvodna razmatranja

Marketing i marketinška komunikacija su pod značajnim utjecajem interneta i razvoja mobilnih tehnologija, gdje Internet pruža nove načine dostizanja ciljnih tržišta po zamjetno nižoj cijeni nego što je to bio slučaj s tradicionalnim medijima (Laudon i Guercio Traver, 2016). Marketeri i oglašivači imaju priliku uz relativno niske troškove identificirati nova ciljna tržišta i prikupiti informacije potencijalnim potrošačima, prilagoditi ponudu, povećati vrijednost potrošača. Također, razvijeni su i novi efektivni oblici komunikacije s ciljnim tržištima, počevši od marketinga na tražilicama, društvenog marketinga, bihevioralnog ciljanja te e-mail marketinga. Ne tako davno, isključivo su velika poduzeća i korporacije gradila prisutnost na internetu (Ivanov, 2012), uglavnom preko svojih službenih stranica tretirajući ih kao produžetak tiskovnih medija putem kojih su pružali osnovne informacije o svom poslovanju. U samo dvadesetak godina, upotreba interneta je prešla od pasivne upotrebe i zadovoljavanja forme u neizbježnu poveznicu između poduzeća i sudionika. Pri tom, nije važno radi li se o malim, srednjim ili velikim poduzećima koja se natječu na lokalnim, regionalnim ili pak globalnom tržištu. Ivanov (2012) u tom smislu navodi pet odrednica interneta preuzetih od Kleinrock (2010): 1) Internetska tehnologija će biti svugdje, 2) biti će uvijek dostupna, 3) uvijek će biti aktivna, 4) svatko će se moći priključiti u bilo koje vrijeme s bilo kojeg uređaja i sa svake lokacije, 5) biti će nevidljiva.

S marketinškog aspekta, razvoj interneta je značio izvjesne pomake u značenju i provođenju marketinških aktivnosti, ali i u poimanju konkurentne prednosti te vrijednosti za kupca. Cilj digitalnog marketinga jest graditi veze potrošača s poduzećem, kako bi potonja mogla ostvarivati iznadprosječne povrate na uloženo, kako ponudom superiornih proizvoda i usluga, tako i izgradnjom branda te komunikacijom njegovih vrijednosti ciljnim tržištima. Razvoj profitabilnih veza putem marketinške komunikacije ne predstavlja revolucionarnu ideju, obzirom da su iste u fokusu marketinških stručnjaka i istraživača već desetljećima, međutim specifičnost interneta kao kanala, odnosno medija razlog je pojavi određenih razlika. Laudon i Guercio Traver (2016) navode četiri značajke digitalnog marketinga koje ga razlikuju od tradicionalnih marketinških kanala: personalizacija, sudjelovanje, isti-sa-istima interakcija (eng. peer-to-peer) i zajednica (eng. communal), međutim valja napomenuti kako nema svaki vid digitalnog marketinga sve navedene značajke. Ukoliko se usporedi video marketinška poruka na računalu (npr. oglasi na YouTube-u) i televizijski oglas, razlike u formatu nisu vidljive, tim više što se često radi o istim video oglasima

postavljenim na različite kanale. Razlika je međutim u tome što se oglas plasiran putem interneta može prikazivati točno definiranim ciljnim publikama putem ciljanja osobnih interesa, pripadanja zajednicama te pruža mogućnost dijeljenja s povezanim subjektima koji su prisutni online.

2.2. Razvoj digitalnog marketinga

Marketinški je napredak neizbježno povezan s tehnološkim napretkom (Ryan i Jones, 2009), a proces zajedničkog razvoja moguće je pratiti prema fazama:

1. nova se tehnologija pojavljuje, a koriste ju pretežito rani usvojitelji i tehnološki entuzijasti
2. tehnologija postaje sve popularnija, čime pridobiva pažnju marketinga
3. inovativni marketeri istražuju mogućnosti primjene novih tehnologija s ciljem dostizanja ciljne publike
4. upotreba nekoć nove tehnologije postaje norma te se primjenjuje u standardnoj marketinškoj praksi

Printani mediji, radio, televizija i sada Internet su sve primjeri velikih napredaka u tehnologiji koji su doveli do promjena u vezama između marketera i potrošača na globalnoj razini. Iako se marketing u velikoj mjeri temelji na tehnologiji, odnosno mogućnostima koje ona donosi, u fokusu je uvijek čovjek. Drugim riječima tehnologija je zanimljiva s marketinškog aspekta ukoliko efektivnije povezuje ljude i poduzeća. Dakle, napredak u tehnologiji ima potencijal otkrivanja potpuno novih tržišta te uzrokovanja radikalnih pomaka u postojećima. Trenutno se novim smatraju digitalne tehnologije, internet i softverske aplikacije koje se na njemu temelje, kao i uređaji koje omogućavaju povezivanje s Mrežom (eng. Web) i s drugim pojedincima, bez obzira na mjesto, vrijeme i način.

Posebno mjesto u pružanju prethodno spomenutih mogućnosti ima Web 2.0 tehnologija, za koju Ryan i Jones (2009) smatraju da nije samo revolucija u tehnologiji, već evolucija u načinu na koji ju ljudi koriste. Podrazumijeva iskorištavanje distribuiranog suradničkog potencijala interneta u povezivanju i komunikaciji s drugima, bez obzira na prostorna ograničenja, od stvaranja online zajednica do dijeljenja znanja, misli i ideja. Zahvaljujući u velikoj mjeri upravo Web 2.0 tehnologiji potrošači imaju neprikosnovenu kontrolu, obzirom da mogu birati kakav sadržaj, kada i kako žele konzumirati. Osim toga, mogu kreirati vlastiti sadržaj te ga dijeliti s povezanim osobama i svijetom i to besplatno. S aspekta marketera navedena evolucija u shvaćanju tržišta i pomaci u ponašanju potrošača donose niz novih izazova. Kako potrošači neprestano pronalaze nove načine

komunikacije, biraju informacije i zabavni sadržaj kojeg konzumiraju, sukladno tomu i sve veći značaj nišnih tržišta, pred marketerima je imperativ pomaka u vlastitom pristupu povezivanja s ciljnim tržištem.

2.3. Strategija digitalnog marketinga

Digitalni je marketing moguće smjestiti u okvire temeljne marketinške polaznice – 4P: mjesto, cijena, proizvod i promocija, što prema Ryanu i Jonesu (2009) olakšava razumijevanje praktičnih implikacija sveobuhvatnih promjena do kojih je došlo tehnološkim napretkom.

Mjesto u ovom kontekstu predstavlja Internet, koji se sastoji od preko milijarde ljudi diljem cijelog svijeta povezanih na Web. Pojedinačni razlozi i ciljevi povezivanja se razlikuju, međutim temeljni je povezivanje, bilo da se radi o komunikaciji, kupovini ili informiranju, a pri čemu se mogu koristiti različiti uređaji, računala, tableti, pametni telefoni, satovi itd.

Cijena je kritičan element, jer svaki subjekt kojem je u cilju provođenje transakcije mora biti konkurentan, a definiranje cijena je transparentno. Naravno, nije prioritet imati najnižu cijenu, već da cjelokupna ponuda vrijednosti odgovara ciljnom tržištu, odnosno da je uvjerljiva. Ukoliko je proizvod ponuđen po nerealno visokoj cijeni biti će vidljivo na nizu stranica specijaliziranih za usporedbu cijena, na forumima i stranicama za osvrte gdje potrošači iznose svoja mišljenja i iskustva u rukovanju proizvodima.

Proizvod se u online kontekstu odnosi na jedinstvenu prodajnu ponudu poduzeća. Kvalitetan proizvod koji ispunjava svoju svrhu je i dalje temelj uspješnog marketinga, ali je posebno ključan u online sferi poslovanja. Tomu je tako jer onaj proizvod koji isporučuje opipljive koristi i ispunjava stvarnu potrebu daje potrošaču stvarnu percepciju vrijednosti. Kvalitetan proizvod je i temelj efektivnog rada marketera, obzirom da je održiva ponuda preduvjet uspješnog angažiranja potrošača i uvjeravanja u kupnju. Suprotno, ukoliko se marketinški napori ulože u promociju proizvoda koji ne opravdava svoju cijenu i/ili ne ispunjava svoju namjenu, neizbježno će doći do protuučinka, kroz izjave i iskustva nezadovoljnih kupaca na društvenim mrežama i stranicama namijenjenim korisničkim osvrtima.

Promocija je jednostavno rečeno, sve ono što poduzeće radi, offline i online, u svrhu uspješne ponude i prodaje proizvoda, pridobivanja novih kupaca i zadržavanja postojećih. U online kontekstu, temelji promocije su:

1. Službena web stranica je središte digitalnog tržišnog nastupa i najvažniji element cjelokupne strategije digitalnog marketinga. Riječ je o digitalnom vlasništvu prema kojem

se usmjeravaju sve ostale online marketinške aktivnosti s ciljem postizanja konverzije, odnosno poticanja ciljnog tržišta na poduzimanje željenih aktivnosti.

2. Optimizacija za tražilice (eng. Search engine optimization, dalje SEO), koja je sastavni dio uspješne web stranice. Predstavlja proces usklađivanja sadržaja na web stranici s pretragama ciljnog tržišta te oblikovanje istog na način da bude dostupan i ljudima i tražilicama. Zahvaljujući adekvatno provedenim SEO aktivnostima službena web stranica će se vjerojatno naći u organskim rezultatima pretrage.
3. Plaćeno oglašavanje na tražilicama (eng. Pay-per-click search advertising, kraće PPC) nudi poduzećima mogućnost da plate prioritetnu poziciju u rezultatima pretraživanja putem aukcija za željene ključne riječi ili fraze.
4. Marketing suradnje (eng. affiliate marketing) i strateška partnerstva se odnose na suradnju između organizacija, poduzeća i web stranica s ciljem razvoja uzajamno korisnih veza u promociji proizvoda i usluga.
5. Online odnosi s javnošću predstavljaju korištenje online kanala kao što su objave za javnost, sindikacija članaka i blogovi kako bi se stvorila pozitivna percepcija branda i/ili pozicija u određenom području ili industriji.
6. Društvene mreže su relativno novi marketinški kanal koji nude potencijal preciznog ciljanja oglasa prema nišnim tržištima, a temeljem informacija prikupljenih putem korisničkih profila i navika u korištenju (npr. Facebook, Twitter, Instagram).
7. E-mail marketing je jedan od prvih modaliteta digitalnog marketinga, koji je zabilježio pad u korištenju zbog pretjeranog slanja neželjenih mailova ili spama. Ipak, riječ je o važnom alatu, naročito kada se radi o održavanju postojećih kontakata s kupcima.
8. Upravljanje odnosima s kupcima (eng. customer relationship management) je zadržavanje i održavanje odnosa s postojećim kupcima, kao i razvijanje uzajamno korisnih odnosa. Zahvaljujući digitalnim tehnologijama razvoj i zadržavanje odnosa s kupcima je postalo direktnije i efektnije nego ikad prije.

Obzirom na spomenute pomake u poimanju i primjeni marketinga do kojih je došlo uslijed napretka i razvoja digitalnih tehnologija, razumno je razmotriti kako su utjecali i na ponašanje potrošača, kao jednog od temeljnih činitelja tržišnog uspjeha. Ryan i Jones (2009) se pri tomu pozivaju na rezultate Jupiter Researcha prema kojem su glavni pomaci u ponašanju potrošača zbog primjene i prihvaćanja tehnologija:

- *međupovezanost* – digitalne tehnologije omogućavaju umrežavanje, odnosno povezivanje s drugima mnogo brže i jednostavnije, bilo putem e-maila, instant poruka, mobilnih poruka ili platformi za društveno umrežavanje temeljenih na webu (na primjer Facebook, Twitter ili LinkedIn), odnosno kombiniranjem istih. Potrošači su tako u interakciji s drugim pojedincima koji dijele njihovo mišljenje, na globalnoj razini, a geografska udaljenost i različite vremenske zone gube na značenju. Dakle, riječ je o isti-sa-istima interakciji koja vodi do ojačavanja postojećih društvenih mreža i razvoja novih virtualnih zajednica.
- *tehnologija izjednačava dostupnost informacija* – zahvaljujući dostupnim tehnologijama sadržaj može biti kreiran, objavljen, s brzim pristupm i konzumiran brzo i jednostavno. Kao rezultat, razvidno je kako je potrošačima dostupan širi raspon novosti, mišljenja i informacija nego ikad prije. Potrošači mogu provoditi vlastita nepristrana istraživanja, uspoređujući proizvode i usluge prije kupnje.
- *filtriranje informacija prema značaju je u porastu* – obzirom na prethodno spomenutu količinu informacija kojima potrošač može pristupiti u svakom trenutku, razvila se potreba za filtriranjem onih informacija koje su značajne te ignoriranje onih koje nisu. Digitalni potrošači traže načine na koje informacije mogu agregirati, kategorizirati te odabrati za prikazivanje te rabe značajke za personalizaciju kako bi blokirali sadržaj koji nije relevantan, kao i softverska rješenja za zaustavljanje prikazivanja neželjenih komercijalnih poruka.
- *nišno agregiranje sadržaja je u porastu* – ogromna količina i raznovrsnost online sadržaja omogućava potrošačima da sudjeluju u nizu interesa i hobija. Skupljanje istomišljenika u online okruženju u interesne skupine dolazi do usko definiranih interesa i zahtjeva, gotovo na individualnoj razini.
- *mikro-objavljivanje osobnog sadržaja je u porastu* – zbog interaktivnosti digitalnih tehnologija koja omogućava međusobno povezivanje, potrošačima je na raspolaganju kanal putem kojeg se mogu izraziti online. Objavljivanje vlastitog sadržaja zahtijeva samo ulog vremena i mašte, bilo da se radi o forumima za raspravu, obrascima za povratne informacije, galerijama fotografija, platformi za glasanje ili blogovima. Korisnici objavljuju svoja mišljenja, koja tim činom postaju dostupna svima te traže mišljenja drugih prije nego donesu finalnu kupovnu odluku.

- *pojava "protrošača" (eng. prosumer)* – online potrošači se sve više uključuju u razvoj proizvoda i usluga koje kupuju, a što dovodi do pomaka u moći s proizvođača na potrošača. Zahvaljujući mnogobrojnim platformama, potrošači mogu svoje želje i potrebe direktno poslati proizvođaču, uslijed čega je današnja razina interakcije između poduzeća i krajnjeg korisnika bez presedana. Vidljiva je i promjena poslovnih filozofija i pristupa tržištu kao posljedica navedenih promjena, obzirom da potrošači imaju mogućnost oblikovanja iskustava, komunikacije pa i proizvoda koje im poduzeća isporučuju, tradicionalni koncepti masovne proizvodnje i masovnog marketinga gube na važnosti.
- *sadržaj na zahtjev* – kako digitalne tehnologije postaju sveprisutne u svakodnevnom životu, a što je praćeno ubrzanom prilagodbom poslovnih procesa, tako potrošači svoje potrebe mogu zadovoljiti sve brže, jednostavnije i sa sve manje barijera. U digitalnoj ekonomiji koncepti vremena, lokacije i fizičke prodavaonice postaju sve irelevantniji, a trenutno zadovoljenje potreba imperativ.

2.4. Pojavni oblici digitalnog marketinga

Kako bi maksimizirali profite i efektivnost svojih oglašivačkih napora, poslovni subjekti neprestano traže i razvijaju inovativne oglašivačke prakse, pri tom prihvaćajući nove dostupne tehnologije. Stoga prilikom plasiranja svojih kampanja putem interneta koriste metode ciljanja oglasa koje povećavaju vjerojatnost da njihove promotivne poruke dostignu pravu publiku (Eurostat, 2016).

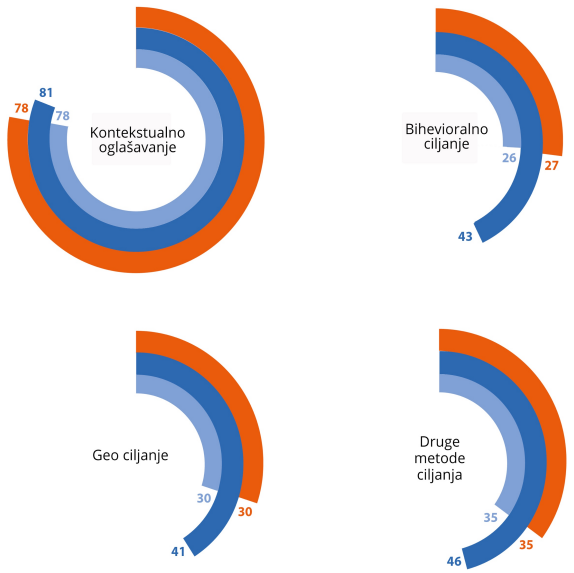

Slika 1. Najkorišteniji oblici ciljanog prikazivanja u Europi, 2017

Poslovni subjekti u ovom smislu koriste tehnologije ugrađene u svoje web stranice i aplikacije, a koje biraju prikazivanje oglasa prema sadržaju kojeg korisnici pregledavaju (Slika 1). Ovaj tip ciljanog prikazivanja oglasa se naziva kontekstualno oglašavanje, a u 2016. godini čak 78% europskih poduzeća se koristilo ovim tipom. Nadalje, na raspolaganju poduzeća imaju i bihevioralno ciljanje, koje podrazumijeva prikazivanje oglasa prema profilima korisnika oblikovanim iz povijesti njihovih pretraživanja prikupljenog od strane

kolačića (eng. cookies). Zanimljivo je da je tek 27% ukupnih europskih poduzeća koristilo bihevioralno oglašavanje u 2016. godini, pri čemu prednjače velika poduzeća. Navedeno i ne čudi, obzirom da je potrebno angažirati kadar educiran za provođenje ovog tipa ciljanja, a što znači i veće izdatke. Slična je situacija i sa geo-ciljanjem, odnosno prikazivanjem oglasa temeljem lokacija, koje se temelji na geo-lokacijskim uslugama kojima se pretraživači koriste prilikom pristupanja internetu. Na taj način moguće je locirati IP adresu korisnika, Wi Fi ili mrežnu lokaciju, a potom i geografsku kao što su zemlja, regija, grad pa čak i poštanski broj, što može biti jako korisno na primjer za oglašavanje restorana koji su u blizini korisnika i slično.

Digitalni marketing se razvio u više pojavnih oblika, ovisno o platformi i načinu realizacije, a temeljni će biti razrađeni u nastavku.

2.4.1. Marketing na tražilicama

Marketing na tražilicama (eng. search engine marketing, dalje SEM) odnosi se na korištenje tražilica za izgradnju i održavanje brandova, dok oglašavanje na tražilicama podrazumijeva korištenje tražilica za poticanje direktne prodaje online korisnicima (Laudon i Guercio Traver, 2016). Stoga se često smatraju najdirektnijim prodajnim kanalom koji se temelji na korisničkoj reakciji na oglase. Osim prodaje, SEM se često koristi i kao sredstvo indirektnog jačanja svijesti o brandu, poticanju prometa na web stranice i blogove, poticanje korisničkog angažmana, kako bi se stekao uvid u percepciju potencijalnih potrošača o brandu te kao potpora drugim oblicima oglašavanja. Također, važna je značajka stjecanje uvida u uzorke korisničkog pretraživanja, mišljenja o proizvodima, najpopularnijih ključnih riječi koje se koriste za pretraživanje te spoznaju o aktivnostima konkurencije na ovom području.

SEM je gotovo idealna tehnika marketinškog ciljanja, jer korisnicima plasira oglase poduzeća upravo u onom trenutku kada traže konkretni proizvod, odnosno kada je potreba aktivirana te se korisnici nalaze u stanju visoke uključenosti. Nemaju samo poduzeća koristi od ovog oblika oglašavanja, već i korisnici i to iz istih razloga, jer im se ne prikazuju oglasim osim ako nisu iskazali interes. Stoga, SEM za korisnike znači manje uloženog truda i kognitivne energije te snižava troškove pretraživanja, uključujući i troškove prijevoza i dolaska do fizičkih prodavaonica gdje opet moraju tražiti proizvod.

2.4.1.1. Tipovi marketinga na tražilicama

Prema Laudon i Guercio Traver (2016), tražilice su u početku provodile nepristrane pretrage web stranica te su većinu prihoda ostvarivale putem davanja oglasnog prostora u zakup.

Ovaj se oblik SEM – a naziva organsko traženje jer podrazumijeva uključivanje rezultata pretraživanja prema nepristranim procjenama od strane algoritama uključenih u tražilice. Tražilice su vremenom postajale gotovo kao telefonski imenici jer su poduzeća plaćala za uključivanje u tražilice, za ključne riječi kako bi se prikazala u rezultatima pa čak i za prikazivanje u sklopu oglasa drugih poduzeća, a da bi se danas došlo do pretežitog modaliteta zakupa ključnih riječi putem aukcija. Oglasi na tražilicama uz plaćanje po kliku su prevladavajući oblik oglašavanja na tražilicama, a podrazumijevaju plasman oglasa prema odabranim ključnim riječima za koje se poduzeća natječu putem ponuda. Potom se oglasi prikazuju kao rezultat pretraživanja, uglavnom u obliku malog tekstualnog oglasa, bilo na vrhu stranice ili s desne strane. U jednostavnom slučaju, što je veća ponuda za pojedinu ključnu riječi ili frazu to je oglas više na stranici rezultata, odnosno ima veću vidljivost. Mrežno oglašavanje putem ključnih riječi (eng. network keyword advertising ili context advertising) je uveo Google putem svog AdSense proizvoda 2002. godine, a podrazumijeva pružanje mogućnosti web stranicama da se pridruže oglašivačkoj mreži koja onda na iste smješta oglase. Dakle, na ovaj način web stranice prodaju oglasni prostor preko AdSense usluge, za koji oglašivači plaćaju, a prihod se dijeli između tražilice i vlasnika stranice. Društveno pretraživanje (eng. social search) je pokušaj korištenja društvenih kontakata korisnika shodno čemu bi se prikazivali rezultati pretraživanja. Dok tražilice koriste algoritme kako bi prikazali najrelevantniji rezultat, društveno pretraživanje pregledava preporuke kontakata, posjete web stranicama te korištenje ”like” opcije. Nastojanje je da se prikazuje manji broj oglasa, ali koji bi bili relevantniji i pouzdaniji.

2.4.2. Prikazivački marketing

Prikazivački marketing (eng. display marketing) odnosi se na plasman vizualnih oglasa u sklopu web stranica, portala i slično. Najstariji i najpoznatiji oblik ovog tipa marketinga su banner oglasi, međutim oni su istovremeno i najmanje efektivni. Uključuju promotivnu poruku pravokutnog oblika, s često uključenim slikovnim elementima, koja se prikazuje na ekranu računala ili mobilnog uređaja. Sličan je tradicionalnim oglasima u tisku, uz prednosti kao što su klik koji vodi na web stranicu, a potom mogućnost identificiranja i praćenja korisnika. Oglasi s bogatim medijima (eng. rich media ads) uključuju animaciju, zvuk i interaktivnost korištenjem Flasha, HTML5, Java i JavaScripta te su značajno učinkovitiji od običnih banner oglasa. Oni korisnici kojima su plasirani oglasi s uključenim videom će šest puta vjerojatnije posjetiti web stranicu oglašivača, bilo direktnim klikom na oglas, upisivanjem adrese oglašivača ili

pretraživanjem. Prijelazni oglas (eng. interstitial ad) je zapravo način smještanja oglasa preko cijele stranice, a između trenutne i željene web stranice. Dakle, uglavnom se radi o oglasima koji su ”umetnuti” u sklopu jedne stranice te se prikazuju prilikom korisničke navigacije po istoj. Uglavnom traju oko 10 sekundi ili manje, pri čemu je korisnik primoran pogledati oglas neko vrijeme dok mu se ne ponudi opcija gašenja oglasa. Video oglasi su slični televizijskim oglasima koji se prikazuju prije, tijekom ili nakon sadržaja kojeg korisnik pregledava. U pravilu se prikazuju automatski, odnosno potrebno je proći određeno vrijeme prije nego se korisniku pruži mogućnost prestanka prikazivanja oglasa.

2.4.3. E-mail marketing

Direktni e-mail marketing je bio jedan od prvih i najefektivnijih oblika online marketinške komunikacije (Laudon i Guercio Traver, 2016). Direktne poruke su se slale onim korisnicima koji su iskazali interes za proizvode, usluge ili brandove te pristali na primanje promotivnih poruka. Koristi e-mail marketinga su višestruke: masovni doseg, praćenje i mjerenje rezultata, mogućnost personalizacije sadržaja i ponuda, poticanje posjeta web stranici, testiranje i optimizacija sadržaja i ponuda, ciljanje prema regiji, demografiji, vremenu u danu i drugim kriterijima. E-mail marketing kao oblik promocije ne iziskuje značajne financijske izdatke, cijena slanja tisuća mailova jednaka je slanju jednog. Zapravo, za većinu poduzeća primarni je trošak prikupljanje ili kupnja liste korisnika, gdje je kupljena lista značajno manje efektivna od stečene sa nižom stopom otvaranja i klikanja na mail. Stopa klikanja (eng. click through rate) u pravilu ovisi o ponudi poduzeća, proizvodu, ciljanu, a u prosjeku se kreće oko 3% do 4%.

Iako se putem e – mail marketinga promoviraju prodajne ponude, može se koristiti kao dio multikanalne marketinške kampanje s ciljem ojačavanja snage i prepoznatljivosti branda. Tri su temeljna problema s kojima se e-mail marketing suočava: spam (komercijalne poruke koje su poslane bez prethodnog odobrenja ili pristanka na njihovo primanje), softverska rješenja za kontrolu spama koja miču velik dio iz primljene pošte korisnika i e-mail liste s lošim profiliranjem korisnika. U pravilu, e-mail najbolje djeluje kao sredstvo za održavanje veza s korisnicima, ali loše za pridobivanje novih korisnika.

2.4.4. Marketing suradnje

Marketing suradnje (eng. affiliate marketing) je oblik marketinga gdje poduzeće plaća proviziju, uglavnom između 4% i 20% drugim web stranicama i blogovima za preusmjeravanje

korisnika na njegove web stranice. Uglavnom uključuje plaćanje po uspjehu, dakle suradnik ostvaruje prihod samo ukoliko korisnici poduzmu odgovarajuću radnju, npr. kliknu na link ili izvrše kupnju. Prema Laudon i Guercio Traver (2016) oko 10% svih online prodaja se odvija preko suradničkih programa.

2.4.5. Društveni marketing

Društveni marketing i oglašavanje (eng. social marketing and advertising) uključuje korištenje online društvenih mreža i zajednica za izgradnju brandova i poticanje online prihoda (Laudon i Guercio Traver, 2016). Društvene su mreže zanimljive s marketinškog aspekta jer su njihovi korisnici skloniji razgovoru o proizvodima, usluga i brandovima, odnosno preporukama. Oglašivačima nude sve glavne oglasne formate, od banner oglasa, video formata do sponzoriranog sadržaja. Potencijal društvenih mreža je prepoznat do te mjere da je za gotovo sve brandove imati profil na društvenim mrežama postalo norma kao i imati svoju web stranicu. Neka su poduzeća, kao na primjer Coca Cola, ugasila web stranice namijenjene određenim proizvodima te umjesto toga otvorila odgovarajuće profile. Blogovi i online igre također se mogu koristiti u svrhe digitalnog marketinga. Čitatelji i autori blogova su često višeg stupnja obrazovanja, imaju viša primanja i potencijalni su lideri mišljenja, riječ je o idealnim stranicama za smještanje oglasa za odgovarajuću publiku. Također, obzirom da se radi o sadržaju koji proizlazi ili iz osobnog iskustva ili mišljenja autora, blogovi mogu biti korisni u poticanju viralnih kampanja. Online igre predstavljaju tržište ogromnog potencijala koje se ubrzano širi i na kojem se ostvaruju sve veći prihodi. Obzirom da je za pristupanje igrama potreban uređaj kao što su pametni telefoni, tableti, računala i konzole te internetska veza, riječ je o potencijalnom kanalu za oglašavanje s ciljem povećanja svijesti o brandu te poticanje prodaje vezanih proizvoda i usluga.

2.4.6. Mobilni marketing

Mobilni marketing (eng. mobile marketing) je u brzom porastu te je stoga sve značajnije, dijelom zbog sve moćnijih uređaja, bržih mreža, bogatog sadržaja i video oglasa (Laudon i Guercio Traver, 2016). Važnost proizlazi iz činjenice da je svakodnevna upotreba mobilnih uređaja sve veća, do te mjere da dnevno čak oko 2,25 milijarde ljudi pristupi internetu s istih. Mobilni marketing uključuje upotrebu banner oglasa, bogatih medija, videa, igara, e – maila, tekstualnih poruka, QR (Quick Response) kodova, kupona i sličnih, a koji mogu biti prikazanu u sklopu mobilne web stranice, unutar aplikacija ili igara. Također, oglasi mogu biti prilagođeni za mobilne platforme na način da se oglasi prikazuju prema lokaciji korisnika.

Aplikacije na mobilnim uređajima predstavljaju marketinšku platformu koja se pojavila u proteklom desetljeću. Radi se o načinu postizanja web korisničkog iskustva bez pristupanja pregledniku, a putem kojeg je moguće obaviti niz zadataka, od čitanja novina do kupovine. Korisnici putem aplikacija određenim sadržajima mogu pristupiti mnogo brže i jednostavnije nego putem preglednika, a osim toga počinju i utjecati na dizajn i funkcionalnosti klasičnih web stranica, jer je korisnicima izgled, osjećaj i iskustvo korištenja aplikacija privlačno te je njihovo korištenje u porastu.

2.4.7. Marketing prikupljanja kontakata

Marketing kreiranja kontakata (eng. lead generation marketing) koristi višestruke oblike online prisutnosti kako bi se prikupili kontakti koje je kasnije moguće konvertirati u potrošače kroz telefonske pozive, mailove ili drugim sredstvima. Ovim se dijelom digitalnog marketinga često bave specijalizirane agencije i poduzeća koje pomažu drugim poslovnim subjektima u kreiranju web stranica, e mail kampanja, društvenih mreža i blogova. Cilj je navedenih aktivnosti optimizirati prikupljanje podataka, a kasnije i upravljanje kontaktima kroz naknadno kontaktiranje, pratiti interakcije te zajedno s podacima iz sustava za upravljanje odnosima s kupcima donositi zaključke i implikacije odnosa poduzeća sa svojim (potencijalnim) kupcima.

2.4.8. Marketing sadržaja

Marketing sadržaja (eng. content marketing) kreira kampanju koja je bazirana na sadržaju povezanim s brandom, a potom pokušava osigurati plasman istog na nizu web stranica. Može se raditi o člancima, infografikama, studijama slučaja, interaktivnim grafikama pa čak i tradicionalnim objavama za javnost. Cilj marketinga sadržaja je povećati broj posjeta službenim web stranicama poduzeća, organsko rangiranje na tražilicama te angažman na društvenim mrežama (Libert, 2015, citiran u Laudon i Guercio Traver, 2016).

2.4.9. Sponzorstva

Sponzorstva podrazumijevaju plaćanje određene naknade za povezivanje imena oglašivača s izvjesnom informacijom ili događajem kako bi se ojačao brand u pozitivnom, ali u ne pretjerano komercijalnom smislu. Primarni cilj sponzorstva je upravo potaknuti svijest o brandu, a ne povećati prodaju. Uobičajeni oblik je ciljani sadržaj (eng. advertorial) gdje je komercijalna poruka uklopljena u uredički sadržaj kako bi bio privlačniji i vrjedniji ciljnim skupinama.

2.4.10. Nativno oglašavanje

Riječ je o oglašavanju koji su oblikovani tako da sliče uredničkom sadržaju, a iako je doživio novu promjenu i ulogu u eri digitalnog marketinga Laudon i Guercio Traver (2016) navode kako nije riječ o novom fenomenu. Tradicionalno nativno oglašavanje uključuje televizijske info-reklame, novinske oglasne članke pa i cijele dijelove časopisa koji su dodijeljeni poduzećima da uklope svoj promotivni sadržaj u sam časopis. U online svijetu, nativni se oglasi najčešće nalaze na društvenim mrežama, Facebook Newsfeedu, Twitter timelineu ili Pinterest Promoted Pinu. Nativni su oglasi naročito zanimljivi u slučaju mobilnih uređaja čiji ekrani nemaju mjesta za banner i druge slikovne oglase s desne strane pa su stoga promotivne objave koje izgledom i sadržajem odgovaraju uobičajenim adekvatno rješenje.

Dakle, nativni oglasi oponašaju urednički i korisnički sadržaj te su smješteni van prostora namijenjenog oglasima i imaju oznaku da se radi o promoviranom sadržaju. Ipak, Laudon i Guercio Traveer (2016) navode kako su istraživanja pokazala kako ih 35% korisnika ne prepoznaje kao promotivni sadržaj. Stoga ne čudi kako su imaju veći utjecaj na korisnike te se pregledavaju oko 53% više nego slikovni oglasi, podižu vjerojatnost kupovine za oko 18% te je dvostruko veća vjerojatnost njihova dijeljenja s obitelji i prijateljima nego je to slučaj s običnim oglasima.

3. E – trgovina

U proteklih nekoliko desetljeća Internet te povezane tehnologije i protokoli svoje mjesto su našli u automatizaciji pojedinih poslovnih procesa, što se često navodi pod jedinstvenim pojmom e-poslovanja. Pojam e-poslovanja često se poistovjećuje s e-trgovinom, međutim općenito govoreći e-poslovanje je, prema Cullen i Taylor (2009) koncept koji podrazumijeva provođenje poslovnih aktivnosti unutar i između organizacija, kroz korištenje informacijsko komunikacijskih tehnologija temeljenih na internetu. S druge strane, autori e-trgovinu smještaju unutar e-poslovanja, navodeći kako je riječ o korištenju elektronskih sustava u razmjeni dobara, usluga i informacija. Drugim riječima, radi se o dijelu cjelovitog internetski potpomognutog poslovanja, čije se aktivnosti temelje na razmjeni između postojećih i potencijalnih partnera, dobavljača i kupaca. Baron i sur. (2009) nadalje razlučuju e-trgovinu orijentiranu na potrošače (B2C) te onu orijentiranu na poslovne subjekte (B2B), pri čemu potonja, iako manja brojem transakcija, prednjači njihovom vrijednošću te se ukupna vrijednost B2B transakcija mjeri u trilijunima dolara samo na području SAD – a.

Laudon i Guercio Traver, (2016) definiraju dva obilježja e-trgovine: komercijalne transakcije, koje uključuju razmjenu vrijednosti za proizvode i usluge te digitalno potpomognute transakcije koje obuhvaćaju sve transakcije koje se odvijaju putem digitalnih kanala, bilo da se radi o Internetu, Mreži (eng. World Wide Web, dalje Web), mobilnim aplikacijama i pretraživačima. Sve više pojedinaca i poslovnih subjekata koristi Internet i mobilne uređaje kao sredstvo provođenja trgovinskih aktivnosti, pri čemu manja, lokalna poduzeća nastoje iskoristiti prednosti online i mobilnih platformi kako bi smanjila troškove te posljedično povećala profitabilnost poslovanja. Razvili su se čitavi brandovi koji djeluju isključivo online, dok postojeći (npr. Tesco, Konzum i drugi) koriste e-trgovinu kao proširenje svoje svekanalne (eng. omnichannel) poslovne strategije u nastojanju održavanja i ojačavanja dominante tržišne pozicije. S aspekta pojedinačnih korisnika, promjene koje uključivanje digitalnih tehnologija u poslovne operacije donosi imaju višestruke posljedice. Prije razvoja e-trgovine marketing i prodaja dobara su se temeljile na masovnoj proizvodnji, komunikaciji i prodaji. Pri tome su marketeri potrošače tretirali kao pasivne ciljne skupine svojih oglašivačkih i komunikacijskih napora, s temeljnim ciljem trenutnog povećanja prodaje te kreiranja dugoročnih percepcija o proizvodu/brandu. Proizvodi su se kretali kroz dobro uspostavljene distribucijske kanale, potrošači su bili ograničeni svojom lokacijom i društvenim okruženjem te nisu bili u mogućnosti tražiti i doći do informacija o najpovoljnijim cijenama i

kvaliteti, tj. postojala je informacijska asimetrija koja je za poslovne subjekte bila izuzetno profitabilna.

Iako e-trgovina bilježi nevjerojatan porast, Oliviera i sur. (2017) navode kako je za većinu potrošača riječ o relativno novom konceptu te je potrebno naći način kako potaknuti njeno kontinuirano korištenje. Indikator normalizacije kupovine preko interneta je postotak pojedinaca koji se svakodnevno koriste internetom te su u određenom proteklom periodu proveli komercijalnu transakciju. U zemljama Europske unije u proteklih 10 godina njihov je broj porastao za gotovo 20 postotnih poena, s nešto ispod 50% u 2007. godini na gotovo 70% u 2017. godini, pri čemu najveće korištenje imaju zapadne i sjeverne zemlje EU. U Hrvatskoj se pak u protekloj godini svega 29% korisnika interneta upustilo u online kupovinu (Eurostat, 2017). Korisnike na kupovinu putem interneta u najvećoj mjeri motiviraju niska cijena i besplatna dostava, ali i pitanje vjeruje li potencijalni kupac online trgovcu. Pogodnost u smislu mogućnosti kupovine od kuće te neovisnost o radnom vremenu prodavaonica, kao i širok raspon ponuđenih proizvoda uz mogućnost usporedbi ponuda, također su značajni razlozi zbog čega se kupci odlučuju na online trgovinu.

Tablica 1. Razlozi za online kupovinu

Razlog	***Postotak ispitanika***
Niže cijene	59%
Kupovina od kuće	53%
Kupovina 24/7	44%
Šira ponuda proizvoda	29%
Jednostavnost usporedbe ponuda i proizvoda	27%
Proizvodi dostupni jedino online	22%
Online korisnički osvrti	18%
Kvalitetnije informacije o proizvodima	7%
Promocija putem maila ili poruka	7%
Utjecaj društvenih mreža i medija	1%

Izvor: Prilagođeno prema Eurostat, 2017

3.1. Pregled razvoja e-trgovine

Početak e-trgovine je teško točno odrediti, ali moguće je pronaći nekoliko njenih preteča kojima se prati primjena i razvoj informacijsko komunikacijskih tehnologija u kontekstu e-trgovine. Kao prvi primjer Laudon i Guercio Traver, (2016) navode farmaceutsko poduzeće Baxter Healthcare koje je tijekom sedamdesetih godina prošlog stoljeća pokrenulo primitivni oblik B2B e-trgovine kojim su bolnice mogle automatski obavljati stalne narudžbe putem telefonskog modema. Ovaj je model u narednom desetljeću unaprijeđen u kompjuterski sustav s mogućnošću unošenja narudžbi te su ga brojna poduzeća diljem SAD – a nastojala kopirati i implementirati u svoje poslovanje. Prednosti takvog sustava automatizacije naručivanja su skraćivanje komunikacijskih kanala, ubrzavanje procesa naručivanja te veća efikasnost i posljedično profitabilnost. Slijedom događaja, došlo je do razvoja standarda elektronske razmjene podataka (eng. Electronic Data Interchange, skraćeno EDI) koji su omogućili poduzećima razmjenu poslovnih dokumenata i provođenje digitalnih transakcija kroz privatne mreže. Na B2C području prvi sustav digitalno potpomognutih transakcija bio je Minitel, francuski sustav video-poruka koji je kombinirao telefon s malim ekranom, a u upotrebu je pušten 1981. godine.

Iako su uključivale transakcije putem digitalnih kanala, nijedna od spomenutih preteča nije uključivala funkcionalnosti interneta, na kojem se e-trgovina i temelji. Početkom e-trgovine Laudon i Guercio Traver, (2016) smatraju pojavu banner oglasa koje su na Hotwired postavili AT&T, Volvo, Sprint i drugi krajem1994. godine te prvu prodaju oglasnog prostora na Netscapeu i Infoseeku početkom 1995. godine. Od tada, e-trgovina se razvijala, sa stalno rastućim funkcionalnostima i mogućnostima te danas izgleda potpuno drukčije nego u svojim počecima sredinom devedesetih godina 20. stoljeća. Autori tako navode kako je u 2015. godine na globalnom online tržištu 1,4 milijardi individualnih kupaca potrošilo oko 1,96 trilijuna eura, a poduzeća čak 14,2 trilijuna eura kupujući dobra, usluge te digitalni sadržaj putem online trgovine, odnosno mobilnih platformi. Usprkos činjenici da e-trgovina postoji relativno kratko, Laudon i Guercio Traver, (2016) navode kako je imala jako burnu povijest koja se može promatrati kroz tri perioda, period izuma (eng. invention) od 1995. do 2000. godine, period konsolidacije od 2001. do 2006. te period ponovnog izuma od 2007. do danas, a koji će biti predstavljeni u nastavku.

3.1.1. Period izuma – 1995. do 2000.

Rane godine su karakterizirane s eksplozivnim rastom i inovacijama s početkom prve široke upotrebe Weba za oglašavanje proizvoda. Tijekom prvog perioda e-trgovina je značila ponudu maloprodajnih, uglavnom vrlo jednostavnih proizvoda, jer tadašnja internetska veza nije omogućavala prodaju kompleksnijih proizvoda. Marketing je bio ograničen na jednostavne, statične vizualne oglase i ne pretjerano moćne pretraživače. Poduzeća koja su imala online prisutnost istu su temeljile na osnovnim statičnim web stranicama na kojima su bili predstavljeni njihovi brandovi. U ovom su periodu razvijeni ključni koncepti e-trgovine, počevši od ranog interneta, osobnih računala pa do LAN mreže, s glavnom idejom da cijeli svijet ima pristup jeftinim računalima koja će omogućiti jedinstveno komunikacijsko okruženje za svih, koje je slobodno od ikakvih utjecaja. S ekonomskog aspekta razvoj ICT tehnologija je trebao značiti tržište gotovo savršene konkurencije, gdje su cijene, troškovi te kvalitetne informacije ravnomjerno distribuirane. U tom scenariju nema barijera ulasku na tržište pa bi se skoro beskonačno mnogo dobavljača međusobno natjecalo, a potrošači bi imali pristup svim relevantnim informacijama na globalnoj razini.

Sve navedeno je rezultiralo euforijom svih uključenih pa su se počeli razvijati teoretski modeli digitalnog tržišta, koji su imali sve subjekte koji postoje i u tradicionalnom tržištu, ali uz specifičnosti proizašle iz naravi tehnologija koje su omogućile njegov razvoj. Tako je pretpostavka da bi došlo do *disintermedijacije,* tj. smanjenog značaja ili potpunog nestanka distributera i veletrgovaca, iz jednostavnog razloga što prodavači i kupci dobivaju direktan pristup jedni drugima. Zbog ovog, gotovo savršenog konkurentnog okruženja transakcijski bi se troškovi uvelike smanjili kao posljedica smanjenih troškova potrage za kupcima, uslijed čega bi ulaganje u masovno oglašavanje postalo besmisleno, ali bi na značaju dobili personalizirani oglasi, prilagođeni svakom individualnom kupcu. Cijene, ali i informacije o troškovima svih proizvoda postali bi potpuno dostupni kupcima, što znači da bi u trenutku mogli doznati koji su to proizvodi najpovoljniji, najkvalitetniji i njima trenutno dostupni. Uslijed sveg navedenog, tržišni posrednici između proizvođača i kupca postaju suvišni, jer njihovo samo postojanje u lancu vrijednosti znači veće troškove za ponuditelje te posljedično veće cijene za kupce.

Nadalje, snažna konkurencija koja bi bila prisutna, uz smanjene transakcijske troškove bi eliminirala postojanje brandova, a samim time i ogromne monopolske profite koji se na njima temelje. Također, bio bi minimiziran značaj zemljopisnog položaja ili jedinstvenog pristupa

sirovinama za proizvodnju. Sve bi cijene proizvoda pale na razinu koja pokriva troškove proizvodnje te osigurava poštenu tržišnu stopu povrata na kapital i dodatnu malu isplatu za poduzetnički trud. Nepoštene konkurentne prednosti bi bile smanjene, kao i ogromni povrati na kapital, što se objedinjuje pod pojmom trgovine bez frikcijskih troškova. Također, online poduzeća zbog karakteristika tehnologije mogla bi stvoriti tzv. zajednice potrošnje (eng. communities of consumption), koje bi dodale vrijednost njihovoj ponudi, kroz sudjelovanje samih potrošača. Ideja je da bi došlo do *efekta mreže* (eng. network effect), tj. do razvoja takvih tehnologija i tehnika koje bi gotovo svi prihvatili i "prešli" u online sferu poslovanja, odnosno da bi svi sudionici u online okruženju imali koristi i primili vrijednosti iz činjenice da svi ostali koriste isti alat ili proizvod.
U stvarnosti se utopijske ideje većeg dobra nisu ostvarile, već su oni koji su prvi uočili tržišnu priliku u određenom području te shodno tomu brzo i reagirali, tzv. *first movers,* ostvarivali enormne povrate na kapital. Oni su postigli veliku korisničku bazu jako brzo, gradili prepoznatljivost branda, kreirali novi distribucijski kanal te kočili razvoj konkurencije putem visokih troškova prijelaza za svoje potrošače, obzirom da su ih navikli na svoja korisnička sučelja i svojstva dostupna samo kod njih.

Kraj prvog perioda dogodio se u 2000. godini kada su vrijednosti dionica novih internetskih kompanija doživjele krah, posljedica čega je bio nestanak tisuća njih (eng. the dot com crash).

3.1.2. Period konsolidacije – 2001. do 2006.

Nakon što su mnoga internetska poduzeća propala, uslijedio je period koji je obilježen ponovnom procjenom potencijala e-trgovine, pri čemu su brojni kritičari predviđali kako neće biti dugog vijeka. Međutim, dogodio se pomak s pretežitog tehnološkog pristupa na poslovno orijentirani pa su tako mnoga postojeća, velika poduzeća počela koristiti mogućnosti interneta u svrhu ojačavanja svoje tržišne pozicije. Naime, poduzeća su prepoznala da postoji novi kanal kojim mogu proširiti vrijednost svojih brandova, a fokus je bio na jačanju postojećeg, a ne na stvaranju novog. Financiranje je također postalo mnogo trezvenije: bankarsko se financiranje počelo bazirati na procjeni profitabilnosti online poslovnih pothvata, a glavne su žrtve bila startup poduzeća koja su sada teško dolazila do potrebnih sredstava.

Proširio se i dijapazon proizvoda i usluga dostupnih online, prethodno dostupnim jednostavnim proizvodima pridružile su se i kompleksnije usluge kao putovanja i financijske usluge, zahvaljujući između ostalog i sve boljoj jačini i brzini internetske veze. Online marketing također napreduje kroz razvoj marketinga putem ključnih riječi na tražilicama, bihevioralnog

ciljanja publike, video oglasa, a koji su bazirani na principu aukcija. Pojavila se i potreba kreiranja šire Web prisutnosti koja nadilazi same službene stranice poduzeća, a uključuje komunikaciju s ciljnim tržištem putem e-maila, vizualnih i kampanja na tražilicama pa čak i kreiranja početnih oblika zajednica potrošača. Poslovna orijentacija prisutna u periodu konsolidacije je zaslužna za pronalazak nove i šire primjene e-trgovine, nudeći prednosti i potrošačima i poduzećima te je obilježena s rastom e-trgovine više od 10% godišnje.

3.1.3. Period ponovnog izuma od 2007. do danas

Početkom ovog perioda smatra se predstavljanje prvog iPhonea 2007. godine te traje do danas, a obilježen je ponovnom transformacijom e-trgovine uslijed brzog razvoja i primjene Web 2.0 tehnologije, razvojem pametnih mobilnih uređaja, uključivanjem lokalnih proizvoda i usluga u ponudu i pojavu ekonomije usluge na zahtjev (eng. on demand service economy) koja je omogućena milijunima dostupnih mobilnih aplikacija te računarstvu u oblaku (eng. cloud computing). Stoga se sasvim opravdano proteklo desetljeće može promatrati kao sociološki, tehnološki, ali i poslovni fenomen. Karakteristike ovog perioda mogu se opisati kao društveni, mobilni, lokalni online svijet, gdje je sadržaj namijenjen zabavi postao jedan od najznačajnijih izvora prihoda. Marketing je također doživio transformaciju kroz rast važnosti društvenih medija i mreža, usmene predaje, viralnog marketinga, ali i repozitorija podataka i analitičkih alata koji poduzećima omogućuju personalizaciju marketinških napora. Poduzeća su proširila svoju online prisutnost priključivanjem na društvene mreže kao što su Facebook, Twitter, Pinterest i Instagram kako bi potrošaču plasirali ciljane marketinške poruke. Također, krajnjim je korisnicima omogućeno aktiviranje neiskorištene imovine, na primjer automobili i slobodne sobe, kroz aplikacije kao što su Uber i Airbnb, a koje se temelje na infrastrukturi mobilnih platformi.

3.2. Karakteristike e – trgovine

Laudon i Guercio Traver (2016) prepoznaju osam temeljnih karakteristika e – trgovine:

1. **Sveprisutnost**

Za razliku od tradicionalnog tržišta koje uglavnom predstavlja fizičko mjesto koje je potrebno posjetiti kako bi se obavila transakcija, e-trgovina je sveprisutna, dostupna bilo gdje i bilo kada te poprima oblik tzv. tržišnog prostora (eng. marketspace). S aspekta potrošača navedeno znači smanjene transakcijske troškove jer više nije nužno potrebno uložiti vremenski i financijski napor kako bi se došlo do ”tržišta” jer ga doslovno imaju u džepu – kupovinu je moguće obaviti i s pametnih telefona. Također, koraci koje je potrebno proći do završetka radnje kupovine postaju

sve jednostavniji i kraći, što rezultira manjim potrebnim kognitivnim naporom. Naime, u ljudskoj je prirodi naći način na koji će smanjiti kognitivni napor te će, u uvjetima danog izbora, uvijek odabrati put koji zahtijeva najmanje truda.

2. Globalni doseg

Nastavno na rušenje fizičkih barijera, globalni doseg za poduzeća znači da im je potencijalno tržište cijeli online svijet. Mjera kojom se određuje ukupni broj potencijalnih kupaca ili potrošača je doseg (Evans i Wurster, 1997, citirani u Laudon i Guercio Traver, 2016). Komercijalne transakcije nadilaze kulturološke, regionalne i nacionalne granice mnogo jednostavnije i troškovno učinkovitije nego tradicionalna trgovina. Spomenuta se značajka ogleda u pojavi brojnih start-up poduzeća specijaliziranih za e-trgovinu, kojima sada ne trebaju ni visoka financijska sredstva za početak poslovanja.

3. Univerzalni standardi

Kako je prethodno bilo govora, u fazi izuma temeljna je bila ideja o efektu mreže, koja podrazumijeva korist koju korisnici imaju od prisutnosti svih ostalih korisnika u istom okruženju. Iako pomalo nevjerojatno, u određenom se smislu dogodilo upravo to, razvijeni su jedinstveni tehnološki internetski standardi, kojima se koriste svi sudionici na internetu. Suprotno tomu, tradicionalne komercijalne tehnologije su često varirale među državama pa su tako na primjer postojali različiti standardi za televiziju i radio, ali i mobilne usluge. Univerzalni tehnološki standardi znače niske troškove ulaska na tržište za poduzeća, smanjuju troškove pretraživanja za potrošače, u smislu potrebnog nižeg uloga truda u pronalazak željenog proizvoda. Dodatna prednost koju potrošači dobivaju jest otkrivanje cijena, upravo zbog postojanja globalnog tržišnog prostora na kojem su dostupni opisi svih proizvoda te pripadajuće cijene. Prisutni su i pozitivni utjecaji mrežnih eksternalija koji proizlaze iz činjenice da svi koriste istu tehnologiju, uslijed čega je prvi put u povijesti moguće saznati broj ponuditelja određenog proizvoda ili sirovine bilo gdje u svijetu, cijene, uvjete dostave te ih sve promatrati u koherentnom konkurentom okruženju.

4. Bogatstvo

Bogatstvo informacija odnosi se na kompleksnost i sadržaj poruke (Evans i Wurster, 1999, citirani u Laudon i Guercio Traver, 2016). Prije razvoja Weba vrijedio je obrnuto proporcionalan odnos između dosega i bogatstva, tj. što je šira publika dosegnuta to je manje bogatstvo poruke. Danas internetske tehnologije imaju potencijal pružanja znatno većeg informacijskog bogatstva od tradicionalnih medija zahvaljujući svojoj interaktivnosti i prilagodbi poruke individualnim

korisnicima. Samim time, moguće je tradicionalno kupovno iskustvo i radnje donekle čak prenijeti u online sferu, kroz razgovor (eng. chat) s online prodajnim osobljem, vizualnim katalozima koji simuliraju prodajne izloge i slično, a što je omogućilo i ponudu još kompleksnijih proizvoda i usluga.

5. Interaktivnost

Interaktivnost je kao značajka proizašla iz karakteristika Web 2.0 tehnologija gdje potrošač više nije pasivni promatrač, već sudjeluje u višesmjernoj komunikaciji s poduzećima, ali i s drugim potrošačima. Zahvaljujući tomu e-trgovina ima prednost nad tradicionalnim komunikacijskim kanalima, gdje je poduzećima bilo nemoguće dobiti direktnu povratnu informaciju o svojim proizvodima i uslugama, a samim time su i brze prilagodbe ponude bile nemoguće. Također, olakšava se i prihvaćanje novih tehnologija od strane (potencijalnih) potrošača, jer direktna, trenutna komunikacija simulira tradicionalnu komunikaciju s prodajnim osobljem.

6. Gustoća informacija

Gustoća informacija se odnosi na ukupnu količinu i kvalitetu informacija dostupnih svim tržišnim sudionicima, i potrošačima i ponuditeljima. Prikupljanje podataka, njihova pohrana i procesuiranje postaju jednostavniji i brži, što vodi do sniženja komunikacijskih troškova. S aspekta potrošača navedeno znači, kako je prethodno bilo govora, jednostavno razmatranje konkurencije te dolazak do točnih cijena i uvjeta dostave. Online poslovni subjekti također imaju koristi od jeftinijih i kvalitetnijih informacija, prvenstveno u smislu razumijevanja svojih kupaca. Nove tehnologije omogućavaju prikupljanje ogromne količine jako specifičnih informacija koje omogućuju segmentiranje kupaca bilo po njihovom uzorku online ponašanja, demografiji, čak i psihografskim karakteristikama. Moguće je čak kombinirati online podatke s offline podacima. Na taj način mogu ciljano usmjeravati svoje oglašivačke napore prema onim kupcima za koje je najvjerojatnije da će kupnju i obaviti.

7. Personalizacija/kastomizacija

Personalizacija oglašivačkih napora u smislu ciljanja oglasa prema potrošačkim profilima kreiranim iz dostupnih podataka je prethodno spomenuta. Dodatna prednost koja proizlazi iz tehnologija e-trgovine je i kastomizacija, prilagodba proizvoda i usluga prema preferencijama potrošača ili njihovom prethodnom ponašanju. Iz interaktivne naravi internetskih tehnologija proizlazi ogromna količina podataka dostupnih o svakom kupcu prije nego obavi kupovinu, konkretno njegovo kretanje na web stranici, pregledani artikli i oni spremljeni u košaricu i slično.

Online trgovac može te podatke koristiti kako bi prilagodio daljnju komunikaciju prema kupcu, kroz preporuke sličnih i komplementarnih artikala, prilagođene oglase pojedinim profilima korisnika, zatim privući nove korisnike koji odgovaraju određenom profilu kupaca ponudom adekvatnih popusta itd.

8. Društvena tehnologija – sadržaj kreiran od strane korisnika i društvene mreže

Evolucija internetskih tehnologija praćena je i razvojem društvenih platformi kroz omogućavanje kreiranja korisničkog sadržaja, kreiranje društvenih veza i mreža te ojačavanje postojećih. Za razliku od tradicionalnih medija, gdje je potrošač konzumirao oglasne poruke koje su bile emitirane na televiziji ili radiju, sada ima mogućnost biti aktivan sudionik u komunikaciji. Pri tom, pružajući informacije o vlastitom iskustvu postaje izvorom za druge, potencijalne potrošače, ali ima i mogućnost odabira koji sadržaj želi konzumirati. Masovna komunikacija tako doživljava pomak ka mnogi-prema-mnogima modelu komunikacije.

3.3. Modaliteti e – trgovine

Na današnjem tržišnom prostoru postoji više modaliteta e-trgovine, ovisno o tome tko su sudionici i na kojim se platformama odvija, a Laudon i Guercio Traver (2016) prepoznaju sljedeće:

1. B2C e-trgovina

Najčešći oblik e-trgovine je poduzeće-potrošač, gdje online poslovni subjekt nastoji dosegnuti individualne potrošače, a uključuje ponudu maloprodajnih dobara, putovanja, smještaja i online sadržaja. Ovaj je modalitet od početaka e-trgovine sredinom devedesetih godina prošlog stoljeća zabilježio eksponencijalni rast u obujmu ponude i broja transakcija.

2. B2B e-trgovina

Na B2B tržištu djeluju poduzeća čiji je cilj prodaja drugim poduzećima, a pojedinačne se transakcije pretežito kreću u višim iznosima. Tako se transakcije na svjetskom online B2B tržištu mjere u trilijunima, a uzevši u obzir da većina još uvijek nije automatizirana jasno je da je riječ o tržištu ogromnog potencijala. Dva su temeljna poslovna modela u sklopu B2B tržišta: mrežna tržišta koja uključuju e-distributere, e-dobavljače i razmjene među njima te privatne industrijske mreže.

3. C2C e-trgovina

Potrošač - potrošač tržišta pružaju mogućnost potrošačima da prodaju dobra i usluge jedni drugima potpomognuti platformama za online transakcije, kakva je na primjer eBay ili poduzećima koji nude uslugu na zahtjev kao što su Airbnb ili Uber. Ovaj modalitet podrazumijeva da potrošač

priprema proizvod za tržište, postavlja ga na platformu za aukciju ili prodaju, dok platforma treba omogućiti pretragu i provođenje transakcija kako bi proizvodi i usluge mogli biti prikazani, otkriveni i plaćeni.

4. **Mobilna e-trgovina**

Mobilna e-trgovina ili kraće m-trgovina podrazumijeva upotrebu mobilnih uređaja kao sredstava koji omogućuju online transakcije. Pametni mobilni uređaj prvo treba biti spojen na Internet nakon čega korisnici mogu provoditi transakcije, od burzovnih aktivnosti, usporedbe cijena različitih ponuditelja, korištenja bankarskih usluga, kupovine proizvoda i usluga itd.

5. **Društvena e-trgovina**

Ovaj se oblik odnosi na e-trgovinu koja je potpomognuta društvenim mrežama i online vezama te se često naziva Facebook trgovinom iako zapravo nadilazi ovu društvenu mrežu. Razvoj modaliteta društvene e-trgovine proizlazi iz niza faktora, uključujući rastuću popularnost prijave na web stranice putem profila na društvenim mrežama, mrežnim obavijestima, alatima nastalim suradnjom više subjekata te društvene pretrage (eng. social search).

6. **Lokalna e-trgovina**

Riječ je obliku e-trgovine koji se temelji na angažiranju potrošača ovisno o njegovoj trenutnoj zemljopisnoj lokaciji. Lokalnim trgovcima je u ovom smislu dostupno više online marketinških tehnika kojim mogu potaknuti potrošača na posjet trgovini, a koje se temelje na ciljanju potencijalnih kupaca putem geolociranja.

3.4. Odnos offline i online trgovine

Faze kupovnog procesa su manje-više jednake bez obzira u kojem se okruženju odvijaju, međutim u razmatranju općeg modela ponašanja potrošača potrebne su izvjesne modifikacije uslijed djelovanja specifičnih faktora. U tom smislu, u obzir treba uzeti karakteristike potrošača i proizvoda, obilježja Web stranice i mobilnih platformi, kao i tradicionalne faktore kao što su snaga branda, oblici marketinške komunikacije te utjecaj online i offline društvenih mreža, kako je prikazano na slici 2.

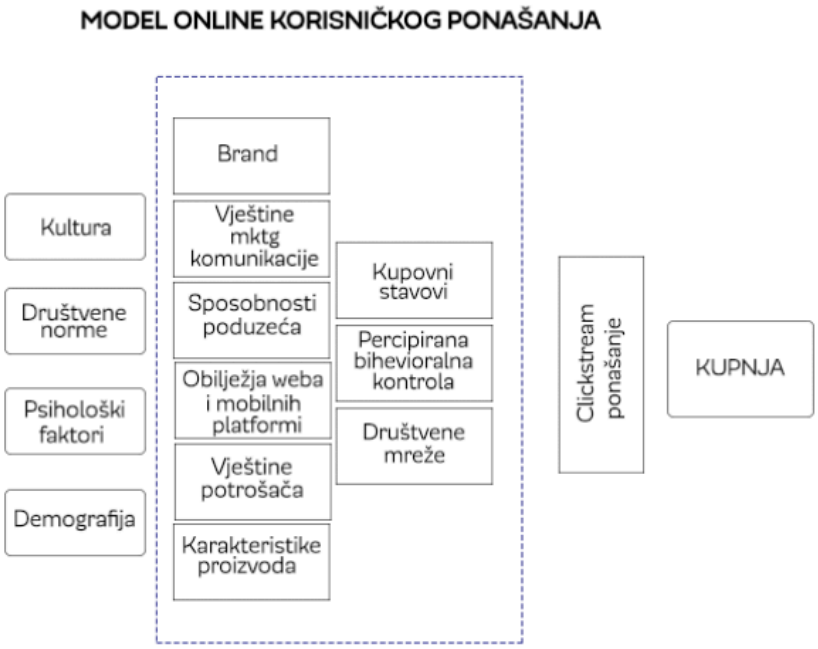

Slika 2. Model online korisničkog ponašanja

Izvor: Prilagođeno prema Laudon i Guercio Traver (2013)

Karakteristike Web stranica i mobilnih platformu uključuju latenciju, tj. kašnjenja u učitavanju, navigaciju i pouzdanost u online sigurnost te je iste moguće usporediti s analognim svijetom. Naime, poznato je kako dizajn prodavaonica može utjecati na ponašanje potrošača pa je stoga razumijevanje kretanja i snalaženja unutar fizičkih prodavaonica značajno za povećanje prodaje i efikasnost promotivnih aktivnosti. Vještine potrošača odnose se na znanje i samopouzdanje u provođenju online transakcija, a one rastu s iskustvom. Karakteristike proizvoda opisuju različite kategorije proizvoda, od onih koje je lako predstaviti, pakirati i poslati, odnosno koje potrošači mogu relativno jednostavno procijeniti prije kupovine, do onih koji uključuju druge varijable kao što su doživljaj, povjerenje i iskustvo, a koje je teško doživjeti u pravom svjetlu prije rukovanja i konzumacije. Izneseni specifični čimbenici zajedno s tradicionalnim kao što su brand, oglašavanje i sposobnosti poduzeća, vode do formiranja povjerenja u poduzeće, očekivanja pozitivnog iskustva te posljedično stavova i kupovini od određene e-trgovine.

Zanimljivo je promotriti u kakvom su odnosu offline i online trgovina, radi li se o konkurentima i supstitutima, gdje uspjeh jednog neminovno znači smanjenje volumena prodaje drugog ili pak mogu biti komplementarni? Laudon i Guercio Traver, (2016) smatraju kako je e-trgovina generator

veće offline prodaje, ali da vrijedi i obratno. Naime, potrošači često alternative pretražuju online, putem tražilica, društvenih mreža, službenih stranica poduzeća i dostupnih e-trgovina, a po donošenju konačne odluke kupovinu ipak obavljaju u fizičkoj trgovini. S druge strane, offline marketing često snažno utječe na online ponašanje pa i kupovinu. Iako su online i blogging zajednice izuzetno utjecajne, najsnažniji mediji u dosegu potrošača još uvijek su print mediji i televizija, gdje pružene informacije o novim proizvodima upućuju potrošače na Web kako bi saznali više te eventualno obavili transakciju. Stoga online i offline kanale ne bi trebalo promatrati odvojeno i kao međusobne alternative, već kao dio svekanalne strategije kojom se prilagođavaju segmentima kupaca različitih preferencija.

3.5. Proces online kupovine – aspekt korisnika i prepreke

Oko 10% Internet korisnika ne želi kupovati online, a kao glavna prepreka spominje se povjerenje koje proizlazi iz straha od prevare, gubitka informacija o kreditnim karticama ili narušavanja osobne privatnosti. Osim povjerenja, kao problemi online kupovine se spominju troškovi dostave, nemogućnost ili otežan povrat te nemogućnost dodira i iskušavanja proizvoda. U skladu s navedenim su i razmatranja Hu i sur. (2008) prema kojima kupac kada se odluči za online trgovinu prolazi kroz transakcijski proces, koji počinje s traženjem proizvoda, usporedbom cijena te evaluacijom kvalitete, naručivanja, dostave i post prodajnih usluga. Zbog naravi online okruženja navedeno podrazumijeva psihološke, procesne te neizvjesnosti proizvoda. Psihološka neizvjesnost odnosi se na emocionalne troškove proizašle iz nesigurnosti transakcije, procesna na odabir prodavača neželjenih osobina, a proizvodna na mogućnost da kupljeni proizvod ne ispuni očekivanja, odnosno ima karakteristike koje se ne podudaraju sa željama kupca. Spomenute neizvjesnosti proizlaze iz asimetrije informacija, tj. dispariteta u relevantnim tržišnim informacijama među sudionicima u transakciji, pri čemu prodavač posjeduje više informacija od kupca.

Online tržišta su, dakle, karakterizirana ”bukom” u komunikacijskim kanalima te su kao takva mnogo rizičnija od tradicionalnih trgovina (Utz i sur. 2011). Kao prvo, dostupno je manje informacija o samim proizvodima, a kupci nisu u mogućnosti procijeniti proizvod u stvarnom svjetlu, ne mogu ga dodirnuti, boje mogu djelovati drugačije ovisno o ekranu i pretraživaču, a razmjena proizvoda za novac se ne odvija istovremeno. U pravilu, kupac prvo mora platiti proizvod, nakon čega slijedi njegova dostava, pri čemu uspjeh transakcija ovisi o tehnologijama koje ih omogućuju. Navedeno uglavnom znači da su transakcije podložne tehničkim greškama koje

su van utjecaja prodavača. Nadalje, većina interakcija u online tržištu je jednokratna jer kupac i prodavač žive na udaljenim lokacijama, postoji rizik da proizvod jednom kad je plaćen neće biti isporučen ili može biti lošije kvalitete, a upravljanje prigovorima može biti sporije i manje efikasno, što vodi do visokih rizika za kupca. Stoga, s aspekta kupca nije bitno samo odabrati pravi proizvod, već i vjerodostojnog prodavača.

Na europskom tržištu većina kupaca, 68%, i dalje preferira tradicionalnu trgovinu navodeću razloge mogućnosti osobne procjene proizvoda, vjernosti trgovinama te navika u kupovini (Eurostat, 2017). Četvrtina ispitanika je kao glavni razlog zbog kojeg ne kupuju online navelo sigurnost plaćanja te probleme zaštite privatnosti, dok oko 20% smatra kako nemaju dovoljno znanja i vještina za uspješno provođenje transakcije (Slika 3). Nešto manje je navelo problem upravljanja prigovorima te povrata proizvoda, a svega 6% smatra dostavu proizvoda problematičnom. Uzevši u obzir prethodna razmatranja, moguće je zaključiti kako i dalje postoji velik dio neiskorištenog tržišnog potencijala, jer je moguće motivirati potencijalne kupce rješavanjem određenih pitanja. Na primjer, sagledavanjem online kanala kao dijela svekanalne strategije moguće je preusmjeriti kupce vjerne određenoj trgovini ili brandu online pružanjem određenih pogodnosti, a kasnije povećati volumen transakcija unakrsnom i/ili dodatnom prodajom. Razvijanje adekvatnog sustava povrata i promptno rješavanje prigovora, kao i smanjivanje broja koraka potrebnih za dovršavanje transakcije također bi potencijalno trebalo motivirati nesigurne kupce na online kupovinu.

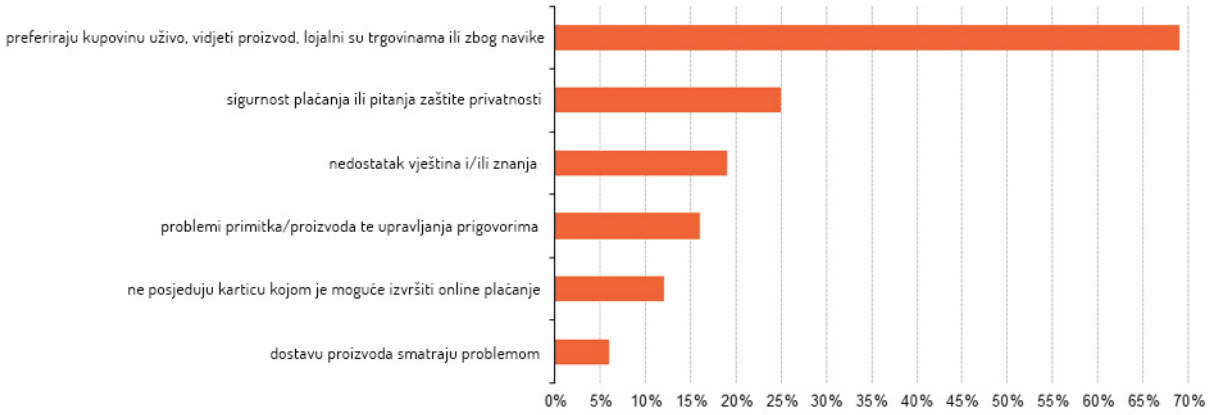

Slika 3. Prepreke online kupovini

Izvor: prilagođeno prema Eurostat, 2017

3.6. Platforme za online kupovinu

Plasman proizvoda i usluga na online tržištu olakšan je razvojem brojnih rješenja u vidu platformi za e trgovinu, čiji se tržišni udjeli razlikuju ovisno o zemljama i regijama, međutim na globalnoj razini većina se transakcija odvija kroz četiri: WooCommerce, Magento, Shopify i BigCommerce.

1. WooCommerce

WooCommerce je s radom započeo 2008. godine, a u ponudi je imao nekolicinu WordPress tema, a do 2017. godine ostvaruje oko 11% ukupnog globalnog tržišta e trgovine, uglavnom zahvaljujući jednostavnoj i besplatnoj implementaciji (Cloudways, 2018). Također, korisnicima nudi veliku fleksibilnost u smislu prilagodbe sučelja te mogućnost integracije niza oblika plaćanja.

2. Magento

Magento drži oko 9% ukupnog globalnog tržišta e trgovine (Cloudways, 2018), uključuje niz alata za analitiku, praćenje i optimizaciju konverzija te se naziva najfleksibilnijom platformom za e trgovinu. Kroz implementaciju računarstva u oblaku korisnicima nastoje pružiti mogućnost kreiranja jedinstvenog kupovnog iskustva za potencijalne kupce uz brzu isporuku i prilagodbu sadržaja (Magento, 2018). Također, jedna je od platformi koja pruža mogućnost društvene e-trgovine kroz integraciju s Facebookom, odnosno sinkronizacije kataloga online trgovina s ovom društvenom mrežom te na taj način monetizacije baze pratitelja. Od lipnja 2018. godine Magento postaje dio Adobe korporacije.

3. Shopify

Riječ je o trećoj najvećoj platformi za e-trgovinu u 2017. godini, s oko 8% tržišnog udjela, što znači da Shopify koristi oko 500 000 e-trgovina s ukupnim volumenom prodaje od 45 milijardi dolara (Cloudways, 2018). Karakterizira ga jednostavno korisničko sučelje te integracija s društvenim mrežama Facebookom i Pinterestom, ali i s Amazon uslugama zbog čega se očekuje porast značaja ove platforme u budućnosti (Shopify, 2018). Shopify pruža mogućnost kupovine direktno iz aplikacija društvenih mreža, što kreira neprekinuto iskustvo za krajnjeg korisnika (eng. seamless experience). Spomenuto je dodatno prošireno mogućnošću direktne komunikacije putem Facebook Messengera, tako emulirajući komunikaciju s prodajnim osobljem. Od ožujka 2018. godine Instagram također uvodi mogućnost direktne kupovine iz aplikacije, a Shopify je jedna od dvije platforme putem kojih je ova opcija ponuđena.

4. BigCommerce

BigCommerce je četvrta platforma prema globalnom tržišnom udjelu u 2017. godini, sa značajnim rastom od 680% godišnje. Riječ je o platformi koja sa svojom agresivnom akvizicijskom strategijom nastoji preuzeti liderski poziciju (Cloudways, 2018). Korisnicima nudi veliku mogućnost personalizacije kupovnog iskustva, od izgleda sučelja, integracije s brojnim aplikacijama, mogućnost praćenja i analitike te odabira platformi i modaliteta plaćanja. Također, nudi i implementaciju u sklopu eBayja, Amazona, Google shoppinga, sinkronizaciju s offline podacima o kupcima te mogućnost plasmana proizvoda na društvenim mrežama Facebooku i Instagramu.

4. Usmena predaja

Tržište je okruženje na kojemu djeluje uvijek rastući broj subjekata s obje strane tržišnog procesa, novi subjekti se pojavljuju, ali i nestaju s tržišta, a svi u borbi za kupca nastoje upravo svoj proizvod/uslugu/brand učiniti najpoželjnijim. Ključna sastavnica strategije pridobivanja i zadržavanja kupca su upravo promotivne poruke, gdje se poduzeća ne suzdržavaju od superlativa pri karakteriziranju svoje ponude. Stoga, razumljiv je konstantni pad u povjerenju potrošača prema poduzećima i njihovim oglašivačkim naporima, napose promotivnim porukama plasiranim putem masovnih medija. Upravo u ovoj situaciji nepovjerenja prema oglašavanju usmena predaja predstavlja put do postizanja značajne konkurente prednosti (Sweeney i sur., 2006). Navedeno je, uz rastući izbor među medijima i porast značaja interneta, razlog što su mnogi u novije vrijeme spominjali čak i ”kraj oglašavanja”. Međutim, sa tim se ne slažu Keller i Fay (2009) te navode kako je to zapravo lažna dihotomija, jer su oglašavanje i usmena predaja u međusobnoj jakoj interakciji. Ipak, kako MacKinnon (2012) navodi oglašavanje je ograničeno na period vremena koje poduzeće ima na raspolaganju za prenošenje poruke, što je uvjetovano i financijskom mogućnostima zakupa prostora, dok se UP odvija gotovo svaki put kada se potencijalni kupac odluči za traženje proizvoda, odnosno kupnju. Usmena predaja se može definirati kao usmena komunikacija između dvije ili više osoba u kojoj se prenose informacije o brandu, proizvodu ili usluzi na nekomercijalnoj razini (Arndt, 1967, citiran u Delozier i Woodside, 1976). Kako Hu i sur. (2008) navode, riječ je o vrijednom marketinškom resursu i efektivnom načinu mjerenja angažmana korisnika kojom se može sreći uvid u vjernost potrošača, a što je kritično za uspjeh proizvoda. U praksi, UP se često smatra dvosjeklim mačem, obzirom da je riječ o neformalnoj komunikaciji među potrošačima koja direktno utječe na uspjeh i neuspjeh proizvoda te je riječ o najefektivnijoj marketinškoj strategiji na svijetu, koju se zapravo najmanje razumije (Cui i sur., 2012). Valencija, odnosno usmjerenje usmene predaje, može biti pozitivna, neutralna ili negativna (Anderson, 1998), a primjeri pozitivne i negativne usmene predaje su raznovrsni. Prvospomenuta se odnosi na prenošenje ugodnih, živopisnih i/ili novih iskustava drugima te žaljenje na proizvod/uslugu u smislu neispunjavanja očekivanja, žaljenje i tračeve za potonju.

Kao posebno značajnu karakteristiku usmene predaje Merton (1968, citiran u Sweeney i sur., 2006) navodi njeno djelovanje na promjenu ponašanja i stavova primatelja informacija u procesu interpersonalne komunikacije. Sweeney i sur (2006) u svojim razmatranjima utjecaja UP – a navode i brojna istraživanja čiji je fokus bio na prihvaćanju novih tehnologija, a rezultati kojih su

pokazali kako zaista postoji pozitivna veza između UP – a i povećane spremnosti na upotrebu novih i (relativno) nepoznatih proizvoda.

Potrošači često dijele mišljenja vijesti i informacije s drugima (Berger, 2014), počevši od neformalnog razgovora o godišnjem odmoru i dojmovima o odgledanim filmovima pa sve do pritužbi i pohvala restorana koje su posjetili. Berger (2014) navodi kako usmena predaja (eng. word of mouth) uključuje rasprave i dijeljenje sadržaja vezanih uz proizvode, direktne preporuke i usputno spominjanje, a može se odvijati kao direktna usmena predaja, razgovorom licem u lice ili kao online usmena predaja, tzv. *word of mouse*.

4.1. Zašto se ljudi uključuju u WoM

Usmena predaja utječe na niz kognitivnih stanja pojedinca: svijest, očekivanja, percepcije, stavove, bihevioralne namjere te na sama ponašanja (Buttle, 1998). Prema provedenim istraživanjima Arndt (1967, citiran u Delozier i Woodside, 1976) je izolirao tri temeljna razloga zbog kojih je neformalni utjecaj razmjene informacije u grupnom okruženju dominantan nad ostalim izvorima informacija:

1. Grupni utjecaj, odnosno usmena predaja, se smatra vjerodostojnim, pouzdanim izvorom informacija koji pomaže u donošenju ispravnih kupovnih odluka
2. Za razliku od masovnih medija, usmena predaja pruža društvenu potporu
3. Pružene informacije često imaju uporište u društvenom pritisku i nadzoru.

Razvidno je kako društveni utjecaj prilikom faze traženja informacija u procesu donošenja kupovne odluke ima izuzetan značaj, čemu u korist idu i rezultati nekih istraživanja prema kojima grupni utjecaj, tj. usmena predaja ima veći utjecaj čak i od osobnih uvjerenja (Delozier i Woodside, 1976).

Ne čudi stoga i interes istraživača za koncept usmene predaje, koji je kao produkt ljudske svijesti i podsvijesti promatran kroz više dimenzija. Tako su Delozier i Woodside (1976) promatrali utjecaj usmene predaje na percipirani rizik, to jest na promjene koje grupni utjecaj uzrokuje u odnosu percipiranog rizika i kupovne odluke. Svoja razmatranja temelje na prethodno provedenim istraživanjima čiji su nalazi međusobno komplementarni jer zajedno pružaju jasniji uvid u utjecaj koji neformalna diseminacija informacija ima na kupovnu odluku, kao i stavove koji joj prethode. Neki od ključnih nalaza u ovom kontekstu su:

1. Kogan i Wallach (1964, 1967), Delozier (1975) – navode ”rizični pomak” kako bi opisali veću razinu spremnosti na odabir rizičnijih alternativa nakon neformalnih grupnih rasprava

u odnosu na period koji im prethodi. Autori moguće objašnjenje nalaze u tezi raspršivanja odgovornosti koja uporište ima u pretpostavci da u grupnom okruženju odgovornost za mogući neuspjeh uslijed visokorizičnih odluka može biti podijeljena s drugim članovima grupe, što rezultira većom spremnošću pojedinaca na poduzimanje rizika.

2. Brown (1968) svoje nalaze temelji na teoriji vrijednosti prema kojoj su spremnost i volja poduzimanje rizika poželjna kulturološka osobina. Navedeno se manifestira na učestalije donošenje odluka potencijalno neuspjelog ishoda u slučaju da su prisutni drugi članovi grupe.
3. Woodside (1968) razmatra uzroke ”rizičnih pomaka” u svjetlu želje za samoispunjenjem. Prema spomenutoj postavci potrošači u situaciji visoko percipiranog rizika pri procjeni alternativa određenog proizvoda iniciraju neformalni grupni razgovor kako bi umanjili vlastitu nesigurnost, dakle upuštaju se u komunikaciju s drugim potrošačima kako bi obranili svoj odabir. U korist ovoj tezi ide i činjenica, kako autor navodi, da su upravo oni pojedinci s visokom percipiranom razinom rizika najviše uključeni u rasprave o proizvodima.
4. Cook (1967) proučava način na koji informacije kolaju obzirom na karakteristike grupe, kao i utjecaj istih na donošenje odluka. Rezultati su pokazali kako u homogenim grupama prisutan veći stupanj donošenja negativnih kupovnih odluka nakon grupnog razgovora o proizvodu. Prema navedenom je moguće zaključiti kako su homogene grupe sklonije donošenju konzervativnijih kupovnih odluka, za razliku od heterogenih koje karakterizira viši stupanj ”rizičnog pomaka”. Razlog takvim suprotnostima autor nalazi u specifičnostima komunikacije među članovima grupa: unutar homogenih grupa članovi se osjećaju slobodnije i bez pritiska mogućeg osuđivanja, obzirom da su svi uključeni sličnih osobina pa tijekom razgovora o proizvodu/usluzi/brandu bez ustručavanja iznose i najkritičnija mišljenja koja potom druge članove odvrati od kupovine dotičnog proizvoda. U heterogenim grupama je, naprotiv, kritičnost u iznošenju mišljenja i iskustva manje prisutna, i razloga što se često radi o poznanicima različitih društvenih pozadina.

Važnost UP je posebno vidljiva u ranim fazama kupovnog procesa, naročito u fazi evaluacije alternativa, jer kako Sweeney i sur (2006) navode pozitivna UP djeluje na smanjivanje percipiranog rizika i to funkcionalnog, vremenskog, financijskog, psihološkog i društvenog. Autori su u tom kontekstu klasificirali navedene oblike percipiranog rizika u dva temeljna: *rizici orijentirani na*

proizvod (funkcionalni i financijski), a koji proizlaze iz neizvjesnosti performansi te financijskog gubitka te *rizici orijentirani na kupca* (psihološki i sociološki te vremenski), koji su definirani kupčevom društvenom okolinom. Prema Cui i sur. (2012) UP je značajan u ranim fazama životnog ciklusa proizvoda, jer su inovatori pod utjecajem masovnih medija iskušali proizvod te kanalima UP prenijeli svoja iskustva drugim skupinama te autori navode kako efekt UP na prihvaćanje novih proizvoda ima oblik obrnute U – krivulje. Također, rezultati istraživanja su pokazali kako je utjecaj UP posebno značajan u zadnjim fazama kupovnog procesa, obzirom da je potvrđivao dobar izbor kupca (Martilla, 1971, cit. u Sweeney i sur., 2006) kroz sprečavanje pojavljivanja kognitivne disonance. Akyuz (2013) navodi kako je UP primarni faktor za 20% do 50% svih kupovnih odluka te da je njen efekt najveći za one kupnje koje se odvijaju po prvi put, odnosno one koje uključuju značajna financijska sredstva. Iz navedenog je moguće zaključiti kako je značaj usmene predaje prisutan u svim fazama kupovnog procesa, i to u različitim ulogama – u početnim fazama dovodi do novih alternativa i olakšava odabir među ponuđenim, smanjuje percipirani rizik i povećava spremnost (potencijalnog) kupca na korak kupnje, dok u postkupovnoj fazi smanjuje nesigurnost kupca u vlastiti odabir.

Usmena predaja je prema Buttleu (1998) određena s pet karakteristika, a to su *valencija, fokus, vremenski okvir, posredovanje* i *intervencija*. Valencija UP može biti pozitivna ili negativna, gdje su spomenute jedna drugoj zrcalne slike, odnosno proizlaze iz zadovoljstva ili nezadovoljstva proizvodom te kupovnim procesom istog. Fokus autor stavlja u kontekst modela šest tržišta marketinga odnosa, u čijem je centru potrošač okružen djelovanjem dobavljača, zaposlenika, utjecajnih sila, preporuka te nastojanja privlačenja. Usmena predaja može prethoditi kupovini (ulazna UP) ili se odviti nakon nje (izlazna UP). Pitanje posredovanja se odnosi na izvor informacija, pri čemu autor navodi kako, usprkos uvriježenom mišljenju, sva UP ne dolazi od strane kupca, niti mora biti eksplicitno zatražena. Kroz pojam intervencije Buttle (1998) obuhvaća nastojanja poduzeća i organizacija za poticanjem i upravljanjem usmenom predajom, što i ne čudi obzirom da se UP odvija među potrošačima te je kao takva van korporativne kontrole.

Sweeney i sur (2006) navode nekoliko faktora koji determiniraju utjecaj UP i ishoda tog utjecaja: *karakteristike pošiljatelja i primatelja poruke te njihova veza/odnos; kontekst unutar kojeg su interpersonalni i neosobni faktori u interakciji* te *karakteristike poruke. Karakteristike pošiljatelja i primatelja poruke te njihova veza/odnos* gdje su dva ključna motivatora koja utječu na prihvaćanje UP u komunikacijskom procesu i to *zanimanje primatelja za pružatelja informacija*

te *stručnost pružatelja* (Dichter, 1966, citiran u Sweeney i sur, 2006), a koji su zajedno činitelji percipiranog kredibiliteta pružatelja kao izvora relevantnih i utjecajnih informacija.

Odnos među sudionicima u komunikacijskom procesu određen je pojmom jakih i slabih društvenih veza, pri čemu se jake veze formiraju među bliskim pojedincima (obitelj i prijatelji), dok slabe veze opisuju odnose među poznanicima. Usprkos tomu što slabe veze imaju nisku relativnu jakost u smislu redovite komunikacije i privrženosti pojedinaca, Granovetter (1983, 1985, citiran u Sweeney i sur, 2006) navodi kako upravo one imaju ključnu ulogu u prenošenju informacija kroz društvene mreže, jer premošćuju razlike između društvenih skupina koje su unutar sebe kohezivne, a međusobno heterogene. Navedeno je u skladu i s razmatranjima istraživanja koje je pokazalo kako informacije koje kolaju među heterogenim skupinama imaju veći stupanj pozitivnog utjecaja na kupovne odluke (Cook, 1967). Dodatnu potvrdu spomenutom donosi Brooks (1957) kroz svoje istraživanje širenja propisivanja novih lijekova od strane liječnika. Primijetio je kako oni liječnici koji su poznanici te se druže na liječničkim skupovima mnogo brže prihvaćaju inovacije u lijekovima od onih liječnika koji su ”izolirani”, odnosno ne pokazuju želju za druženjem. Slabe veze značajne su i u procesu društvenog učenja, kako su pokazala istraživanja Ellison i Fudenberh (1995, citirani u Sweeney i sur, 2006), gdje je pokazano da difuzija informacija ima veću učinkovitost kada su izvori brojni i raznovrsni, ali i veću mogućnost premošćivanja razlika u znanju između homogenih subpopulacija.

Kontekst unutar kojeg su interpersonalni i neosobni faktori u interakciji, a koji je definiran s nekoliko situacijskih faktora, uključujući i inicijativu za razgovorom, pri čemu je efektivnost veća ukoliko je primatelj informacije istu zatražio od pružatelja (Sweeney i sur, 2006). Također, tip proizvoda također ima utjecaj na učinkovitost UP – a, gdje je istraživanje pokazalo kako su primljene informacije značajnije ukoliko se radi o kompleksnim, visoko rizičnim situacijama (kao što su na primjer profesionalne usluge), ali i da UP najveću učinkovitost ima ukoliko se informacija primi iz više izvora. Usmena se predaja pokazala posebno značajnom ukoliko interesna strana nije imala mnogo vremena na raspolaganju za evaluaciju alternativa, ali i kada primatelj nije mogao naći druge informacije koje smatra relevantnim. U konačnici, kao faktor utjecaja i prihvaćanja UP, Sweeney i sur. (2006) navode *karakteristike poruke.* Istraživanje je pokazalo kako je za ishod komunikacije bitna percipirana vjerodostojnost pružatelja informacija, ali i način na koji je poruka isporučena te narav poruke. Posebni se značaj stavlja na ”bogatstvo” poruke, odnosno koliko je živopisno poruka predstavljena, gdje je prihvaćanje UP bilo veće kada je sama informacija bila

inkorporirana u priču s puno detalja, ako je ispričana odgovarajućim tonom te ukoliko je bila popraćena govorom tijela koji ulijeva povjerenje.

Usmena predaja ima dva subjekta, primatelja i pružatelja te će učinak imati samo ako je pružatelj motiviran za razgovor (dijeljenje informacija), odnosno ukoliko je primatelj spreman usvojiti primljene informacije (Lau i Ng, 2001). Lau i Ng (2001) su pregledom literature i raspoloživih rezultata istraživanja identificirali potencijalne motivatore UP i njihove čimbenike za strane uključene u ovaj oblik komunikacije. Prema njima, motivacija za UP u slučaju primatelja može biti po utjecajem *individualnih karakteristika,* kao što su na primjer samopouzdanje i društvenost, *stavovi* u smislu spremnosti na pomoć drugima, *uključenost* u sam proizvod/uslugu te *situacijski faktori*. Nadalje, poticajni faktori primatelja informacija na prihvaćanje UP su pod utjecajem *kredibiliteta izvora*, *homogenosti* i *društvenih veza*, tj. odnosa s pružateljem te *situacijskih čimbenika* kao što je slučaj proizvoda/usluga čija kupnja i korištenje/konzumiranje nosi visok stupanj percipiranog rizika.

Kako je prethodno navedeno, usmena predaja naročito važnu ulogu ima u marketingu uslužnih djelatnosti, obzirom na njihovu neopipljivost koja onemogućuje njihovu pretkupovnu probu, a navedeno je posebno razvidno kod usluga koje su kompleksne ili njihova kupovina i korištenje sa sobom nosi visoku razinu percipiranog rizika (Sweeney i sur., 2006). Iz tog se razloga vjerodostojnima smatraju izvori neovisni od organizacija pružatelja usluga, odnosno oni koji nisu angažirani da promiču dotičnu uslugu, navodi Silverman, (2001, citiran u Sweeney i sur, 2006).

4.2. Odnos pozitivne i negativne usmene predaje

Preteča pozitivne ili negativne usmene predaje su ugodna ili neugodna iskustva korištenja ili konzumiranja proizvoda, navodi Anderson (1998) te u svom razmatranju drugih čimbenika koji prethode usmenoj predaji navodi rezultate više istraživanja i to kako slijedi: relativna stručnost (Feick i Price, 1987; Katz i Lazarsfeld, 1955; Rogers, 1962), uključenost i privrženost (Dichter, 1966, Richins, 1984), percipirane koristi socijalne razmjene (Brown i Rengen, 1987; Dichter, 1966; Rogers,1962) i individualna procjena opasnosti narušavanja morala (Frenzen i Nakamoto, 1993).
U literaturi je prisutna polemika oko toga uključuju li se više zadovoljni ili nezadovoljni potrošači u proces usmene predaje, a oba stajališta imaju uporište u rezultatima istraživanja koja su u fokusu imala odnos zadovoljstva i UP – a. Pobornici ideje o većoj propulziji pozitivnog korisničkog iskustva kao utjecajnog faktora na UP navode zadovoljstvo proizvodom i upravljanjem pritužbama, ali i općenitu sklonost u kontekstu kognitivnih procesa, podražaja i odnosa koji su u svojoj naravi

pozitivni (Holmes i Lett, 1977). Nadalje, uključivanje u pozitivnu usmenu predaju je konzistentno s potrebom pojedinca da se predstavi u pozitivnom svjetlu (Goffman, 1959) ili drugim riječima nastojanjem da se isključi iz negativnog konteksta kako bi se izbjegli osjećaji krivnje, asocijacije s lošim vijestima te straha od otuđivanja sugovornika (Tesser i Rosen, 1975, citirani u Anderson, 1998).

U prilog ideji većeg uključivanja u negativnu usmenu predaju idu u prilog rezultati istraživanja Richins (1983, citirana u Anderson, 1998) prema kojima je nezadovoljstvo veći motivator od zadovoljstva te činjenice da ishodi negativne UP dovode do ishoda koji nose određene psihološke koristi pružatelju informacija, a to su umanjivanje osjećaja tjeskobe, ljutnje ili pak osvete zbog neugodnog iskustva (Richins, 1984).

Obzirom na naravnu različitost pozitivne i negativne usmene predaje, smislena je pretpostavka kako su i motivi za uključivanje u spomenute različiti. Tako Sundaram i sur (1998) u motivacijskoj analizi navode zaključke Dichtera (1966) koji je identificirao temeljne čimbenike pozitivne usmene predaje – *uključenost u proizvod*, gdje je UP sredstvo kojim se *smanjuje napetost ili uzbuđenje* koje kupnja i korištenje proizvoda uzrokuje; *samo poboljšanje* u cilju privlačenja pažnje, pokazivanja stručnosti, dobivanje potvrde od drugih; *uključenost s drugim pojedincima* zbog želje da im se pomogne te *uključenost u poruku*, dijeljenje specifične poruke i povećanje izloženosti određenoj marci. S druge strane, kroz razmatranje negativne usmene predaje, Richins (1983) navodi nekoliko faktora koji istu potiču, a to su *nezadovoljstvo proizvodom, nedostatak mehanizama za upravljanje pritužbama,* kao i *neadekvatno rješavanje pojedine pritužbe* te *neefikasnost popravka lošeg proizvoda.*

Sundaram i sur. (1998) su kategorizirali motive pozitivne i negativne usmene predaje, pri čemu je uočljivo da među njima postoje određena preklapanja. Za pozitivnu usmenu predaju identificirani su motivi: *altruizam* kao čin pomoći drugima, bez očekivanja reciprociteta, tj. povratne usluge, *uključenost u proizvod*, *samounapređenje*, *pomoć* poduzeću koje im je pružilo zadovoljavajući proizvod, dok su za negativnu UP motivi *altruizam, smanjivanje tjeskobe, osveta* te *traženje savjeta.*

5. Korisnički osvrti

Online korisnički osvrti su postali značajan izvor informacija zahvaljujući njihovom brzom širenju (Hu i sur., 2008), zamjenjujući i nadopunjujući ostale izvore informacija o karakteristikama proizvoda (Chevalier, 2004), a potencijalnim su potrošačima od koristi prilikom planiranja kupnje novog proizvoda s kojim prethodno nisu imali iskustva (Cui i sur., 2012). Prije nego je Internet dosegao raznovrsnost i razinu današnjeg korištenja u svakodnevnom životu, potrošačima su uglavnom bile dostupne informacije proizašle iz oglašivačkih napora te drugih izvora koje su pružali isključivo proizvođači i prodavači (Hu i sur., 2011). Potrošači zapravo nisu ni imali drugog izbora nego se osloniti na informacije koje su im pružali poslovni subjekti, a koje su bile upitne vjerodostojnosti te su u nastojanjima donošenja informirane kupovne odluke tražili savjete svog društvenog kruga, tj. oslanjali su se i na usmenu predaju, pri čemu su pak bili limitirani na nekolicinu bliskih osoba i njihovo, često ograničeno, iskustvo.

Razvoj interneta i web 2.0 tehnologija pružio je potrošačima platformu za dijeljenje mišljenja i iskustava o pojedinim poduzećima, proizvodima i uslugama što je dovelo do, kako Hu i sur. (2011) navode, izraženo povećanog oslanjanja na online osvrte drugih korisnika za niz proizvoda i industrija. Korisnički osvrti su postali jedan od najtraženijih izvora informacija, jer su potrošači vremenom postali zasićeni tradicionalnim izvorima informacija, koji su pod kontrolom marketera (Ludwig i sur., 2013. Korisnički su osvrti naročito značajni prilikom plasmana novih proizvoda, jer ukoliko je kognitivna disonanca prisutna čak i kod relativno malenog udjela inicijalnih korisnika koji su svoje nezadovoljstvo voljni iskazati putem online osvrta, mogu ostati dugotrajne posljedice za tržišni uspjeh (Chevalier, 2004). Napredak u informacijskim tehnologijama ne samo da je iz temelja promijenio način na koji se informacije prenose, već nadilazi i tradicionalna ograničenja klasične usmene predaje. Tako potrošači danas mogu jednostavno i slobodno pristupiti informacijama i razmjenjivati mišljenja o poduzećima, proizvodima i uslugama u stvarnom vremenu (Duan i sur., 2008). Internet je postao medij kojim se direktno mogu, bez obzira na geografska ograničenja, dostići brojne publike i stvoriti glasine s izuzetnom efikasnošću i fleksibilnošću. Došlo je do promjene i u principu komunikacije, gdje je aktualan pristup mnogi – prema – mnogima simultani model komunikacije koji podrazumijeva i međusobnu udaljenost sudionika (Chatterjee, 2001).

Koristi koje pojedinac može iskusiti zahvaljujući spomenutom modelu komunikacije su višestruke, a temelje se na dostupnosti tuđih iskustava i procjena tijekom kupovnog procesa i to u

različitim oblicima, s različitih izvora. Posljedično, ovaj oblik komunikacije omogućava online korisnicima da budu i pasivni sudionici u komunikaciji, u smislu pristupa tuđim razgovorima na forumima, online mjestima za osvrte i slično, bez da sami sudjeluju u pružanju informacija.

Cui i sur. (2012) sadržaj kreiran od strane korisnika, naročito online osvrte, navode kao sredstvo pomoći drugim korisnicima – potencijalnim kupcima, u donošenju informiranih odluka o kupnji novih proizvoda te smatraju osvrte jednom od pokretačkih snaga u marketinškoj strategiji novih proizvoda, što e-marketing čini ključnim faktorom. Rezultati istraživanja pokazuju kako potrošači imaju visok stupanj povjerenja u korisničke osvrte, uglavnom zbog uloženog truda i nepristranosti autora osvrta (MacKinnon, 2012). Naime, ispitanici su naveli kako je za pisanje korisničkog osvrta potrebno uložiti izvjestan trud i vrijeme pa njihovi autori zasigurno smatraju jako važnim podijeliti svoje iskustvo s drugima. Navedeno je u skladu i s Utz i sur. (2011) koji su došli do podatka kako pojedini korisnici ulažu do čak i sat vremena u pisanje osvrta. Osim toga kao značajnom stavkom povjerenja smatraju i činjenicu kako autori osvrta za njihovo pisanje nisu plaćeni. U vrijeme brzog razvoja u načinima korištenja i primjene interneta u svakodnevnom životu korisničkim osvrtima se pruža velika važnost pa se tako njihov utjecaj objedinjuje pod pojmom referalna vrijednost ili vrijednost preporuke te se smatra najvažnijom mjerom poslovnog uspjeha (Reichheld, 2003, citiran u Hu i sur, 2008). Naime, pretpostavka je kako se zahvaljujući toj vrijednosti može predvidjeti uspjeh poduzeća točnije nego korištenjem tradicionalnih mjera kao što je zadovoljstvo potrošača, zbog čega osvrti imaju značajne implikacije za menadžerske aktivnosti kao što su izgradnja ugleda i akvizicija novih kupaca.

5.1. Karakteristike online korisničkih osvrta

Specifičnosti online osvrta u velikoj mjeri proizlaze iz značajki okoline i platformi koje su omogućile njihovu pojavu i širenje pa su tako, prema Cui i sur. (2012), njihova temeljna obilježja brzina, pogodnost, širok doseg te odsutnost pritiska prisutnog u direktnoj, usmenoj komunikaciji. U usporedbi s klasičnom usmenom predajom, jedna od prednosti je svakako i mjerljivost (Lee i sur., 2007), koja potrošaču pruža mogućnost jednostavnog pregleda i mjerenja kvalitete i kvantitete pozitivnih i negativnih mišljenja, obzirom da se nalaze u pisanoj formi na određenoj web lokaciji. Količina korisničkih osvrta, kao i njihova stalna dostupnost omogućila je i istraživačke napore, omogućujući razvoj brojnih metrika kojima je moguće predvidjeti uspjeh proizvoda, dijagnosticirati eventualne probleme i njihove uzroke, ali i stjecanje uvida u svijest potrošača.

Tri su temeljne metrike osvrta kojima je moguće determinirati njihov utjecaj (Cui i sur., 2012): volumen, valencija i disperzija. Prema autorima *volumen* je značajan iz jednostavnog razloga što učestalost spominjanja određenog proizvoda u sklopu osvrta vodi do širenja svijesti o brandu. *Valencija* predstavlja kontekst u kojem se proizvod spominje, a može biti pozitivan ili negativan te je posebno značajan jer pruža potencijalnim kupcima uvid u kvalitetu proizvoda, odnosno služi im kao preporuka. *Disperzija* korisničkih osvrta kao karakteristika komunikacija opisuje koliko se brzo usmena predaja širi unutar i između zajednica. Lee i sur. (2007) promatrali su kvalitetu komunikacije ovog tipa kroz četiri dimenzije: relevantnost, pouzdanost, razumljivost i dostatnost. *Relevantnost* predstavlja stupanj u kojem se informacije pružene u korisničkim osvrtima podudaraju s onim koje potrošač želi i traži u nastojanju evaluacije proizvoda, dok se *pouzdanost* odnosi na mogućnost oslanjanja na pružene informacije, odnosno potencijal donošenja ispravne kupovne odluke temeljem istih. *Razumljivost* opisuje stupanj jednostavnosti shvaćanja osvrta, a *dostatnost* dubinu detalja kojim je proizvod opisan u korisničkom osvrtu. Temeljem navedenih se dimenzija razlučuju *visokokvalitetni* i *niskokvalitetni* korisnički osvrti, pri čemu su prvi visoko uvjerljivi jer sadrže detaljne, razumljive, pouzdane i dovoljne za donošenje odluke, dok su informacije sadržane u potonjima suprotnih značajki.

Karakteristika, odnosno metrika korisničkih osvrta koja potiče najviše istraživačkog interesa je valencija, tj. radi li se o pozitivnom, negativnom ili neutraln5om osvrtu. Riječ je dakle o sadržajnom usmjerenju osvrta, a koji se temelji na sentimentu korisnika proizašlom iz iskustva kupovine, konzumacije, korištenja ili rukovanja proizvodom, uslugom i/ili poduzećem. Pozitivni korisnički osvrti su indikator kvalitete i reputacije proizvoda, dok negativni signaliziraju nedostatak povjerenja u proizvod među postojećim korisnicima (Cui i sur., 2012). Tako je pozitivno orijentirani osvrt karakteriziran ugodnim, živopisnim i originalnim opisima iskustva, dok će negativno orijentirani osvrt vrlo izgledno uključivati pritužbe, negativan opis iskustva pa čak i nastojanja omalovažavanja (Anderson, 1998, citiran u Sparks, 2011). Moguće je, dakako, da korisnički osvrt prema valenciji bude i neutralan, što međutim nije vrlo izgledno, uzevši u obzir da je poticaj za pisanje istog devijacija u odnosu na normu (Sparks, 2011), zbog čega dolazi do nepotvrđenih očekivanja ili jednostavno rečeno iskustvo može biti dobro ili loše.

Pan i Chiou (2011) navode kako pozitivne informacije vode do formiranja pozitivnog mišljenja, dok negativne informacije vode do suprotnog, negativnog mišljenja, a samim time i reakcija, držeći sve ostale utjecaje konstantnima. Pretpostavka je dakle, kako će u kontekstu online

kupovine pozitivni osvrti za rezultat imati povećanje prodaje, dok će negativni osvrti dovesti do pada prodaje, što su pojedina istraživanja i potvrdila (Chevalier i Mayzlin, 2006, Dellarocas i sur., 2007, citirani u Utz i sur., 2012). Ipak, spomenuto je shvaćanje utjecaja valencije na kupovnu namjeru linearno, simplificira ponašanje potrošača u online okruženju te kao takvo nije reprezentativno, a što su Pan i Chiou (2011) potvrdili nastavljajući se na tu tezu.

Jedna od značajki online korisničkih osvrta je, za razliku od klasične usmene predaje, simultano prikazivanje pozitivnih i negativnih informacija proizašlih iz različitih izvora na jednom mjestu (Lee i sur., 2007) pa stoga korisnici pristupaju procesu prikupljanju društvenih informacija (eng. social information pooling) (Utz i sur., 2012). Spomenuti proces opisuje korištenje društvenih medija, foruma, sustava povratnih informacija te stranica posvećenih korisničkim osvrtima, u svrhu pronalaska visokokvalitetnih informacija. Sukladno tome, potencijalnim potrošačima prilikom procjene osvrta od koristi mogu biti i sustavi ocjena, npr. putem zvjezdica ili palac gore/dolje (eng. thumbs up/down) (Cui i sur., 2012).

Bez obzira radi li se o pozitivnim ili negativnim korisničkim osvrtima, neupitan je njihov utjecaj na individualnu reakciju u smislu donošenja kupovne odluke (Kusumasondjaja i sur., 2012), iako autori napominju kako su rezultati prethodnih istraživanja snage pozitivnih i negativnih informacija polučila kontradiktorne rezultate pa tako navode pojedina istraživanja koja sugeriraju da pozitivni osvrti potiču snažniju reakciju potencijalnih kupaca (Snyder i Cowles, 1979; Snyder i sur., 1977; Jones i sur., 2006; Klayman i Ha, 1987), dok je prema drugima utjecaj negativnih informacija značajniji (Mizerski i sur., 1982). Nadalje, u sagledavanju značaja valencije razumno je postaviti pitanje vodi li ona sama do utjecaja, odnosno promjene ponašanja potrošača ili postoje povezani čimbenici koji ju pojačavaju. U tom smislu potrebno je obratiti pozornost i na relativnu proporciju pozitivnih i negativnih osvrta u cjelokupnoj masi onih koji se odnose na određeni proizvod, smatraju Cui i sur. (2012). Riječ je o važnom indikatoru prevladavajućeg mišljenja postojećih potrošača određenog proizvoda obzirom da predstavlja presjek cjelokupnih iskustava, odnosno iskustava, a u praksi je često jednostavno predstavljen srednjom ocjenom. Relativni odnos pozitivnih i negativnih osvrta je promatran i sa stajališta njihove (ne)podudarnosti, gdje su predstavljeni pojmovi pozitivno i negativno nepodudarnih osvrta kao utjecajnih čimbenika na percepciju korisnosti osvrta (Kusumasondjaja i sur., 2012). Potvrđeno je, naime, kako su pozitivno nepodudarni osvrti, tj. pozitivni osvrti suprotstavljeni pretežito negativnim osvrtima, procijenjeni

korisnijima od negativno nepodudarnih osvrta, dakle negativnih osvrta suprotstavljenih pretežito pozitivnim osvrtima.

Većina autora (Utz i sur., 2012; Kusumasondjaja i sur., 2012; Cui i sur., 2012; Lee i sur., 2007; Sparks, 2011) slaže se kako prosječni potrošač više pažnje obraća na negativne osvrte, sukladno čemu imaju i veći utjecaj na kupovnu namjeru od pozitivnih osvrta. Racionalizacija iznesenog stava može se pronaći u konceptu sklonosti negativnosti (eng. negativity bias) kao psihološke tendencije pojedinaca da tijekom evaluacije kvalitete proizvoda ili usluge pružaju veći dijagnostički značaj negativnim informacijama (Cui i sur., 2012). Naime, pojedinčevo društveno okruženje pretežito sadrži pozitivne signale pa stoga oni negativni privlače više pozornosti te se percipiraju kao odmak od ustaljene norme, što za rezultat ima stimuliranje izvjesne reakcije, konkretno u slučaju online trgovine to bi bilo potpuno odustajanje od kupovine ili intenzivnije traženje i evaluacija alternativa. S navedenom postavkom sklonosti negativnosti se deskriptivno slažu i drugi autori pa Kusumasondjaja i sur., (2012) i Lee i sur. (2007) navodeći dijagnostičku ulogu negativnih osvrta, dakle čak i ako su dostupni pretežito pozitivni korisnički osvrti, većina potrošača će tražiti negativne informacije koje će im pružiti uvid u potencijalne poteškoće u korištenju proizvoda. Uporište navedeni stavovi imaju i u teoriji transakcijskih troškova, jer negativni signali vode do više percipirane nesigurnosti i rizika te posljedično viših transakcijskih troškova za potencijalnog potrošača, a što rezultira smanjenom prodajom (Hu i sur., 2008). Ipak postoje indicije da manja relativna proporcija negativnih osvrta može značiti i veću prodaju, jer će prosječni potrošač lakše primijetiti proizvod (Utz i sur., 2012), upravo zbog ranije iznesenih sklonosti pojedinaca, a osim toga jedinstveno pozitivni osvrti mogu djelovati sumnjivo, dok u pretežito pozitivnim ocjenama jedan negativan može biti i signal vjerodostojnosti.

Različiti proizvodi i usluge imaju i različite karakteristike pa je stoga razumno pretpostaviti kako će potrošači imati specifične pristupe pretraživanja informacija obzirom na kategorije proizvoda. U teoriji, karakterstike proizvoda se kategoriziraju u tri skupine – karakteristike pretraživanja, iskustva I povjerenja (Pan i Chiou, 2011; Cui i sur., 2012; Hu i sur., 2008). Prve je jednostavno procijeniti jer imaju takve atribute o kojima je moguće prikupiti sve potrebne podatke prije kupovine, kao što su na primjer elektronski uređaji. Drugi, proizvodi s karakteristikom iskustva su kompleksniji za procjenu, jer sadrže atribute koje je nemoguće u potpunosti procijeniti prije kupnje, na primjer filmovi i knjige. Treću je skupinu proizvoda, onih s karakteristikom povjerenja, potrošaču problematično procijeniti čak i nakon njihova korištenja, takvo je na primjer

obrazovanje ili zdravstvene usluge. Jasno je kako će za proizvode s karakteristikom pretraživanja potencijalni kupac relativno jednostavno donijeti kupovnu odluku, pristupiti će informacijama dostupnim na službenim stranicama prodavača te iskustvima postojećih korisnika, temeljem čega bez mnogo uloženog napora može steći uvid radi li se o proizvodu koji mu odgovara. Suprotno tomu, druge dvije kategorije proizvoda/usluga je znatno kompleksnije procijeniti temeljem dostupnih službenih informacija, jer u velikoj mjeri ovise o subjektivnom osjećaju zadovoljstva i ispunjenosti korištenjem proizvoda. Također, potrošačima često nedostaje potrebno znanje i stručnost za evaluaciju elemenata iskustva i povjerenja u ovim skupinama proizvoda što vodi do višeg percipiranog rizika prilikom donošenja kupovne odluke. Upravo iz tog razloga u njihovoj procjeni, naročito u online okruženju, značajnu ulogu imaju korisnički osvrti gdje potencijalni kupci traže afektivne signale iskustava postojećih potrošača, pri čemu pozornost obraćaju i na volumen dostupnih osvrta. Cui i sur. (2012) smatraju kako je volumen korisničkih osvrta indikator popularnosti određenog proizvoda ili usluge pa potrošači, u nedostatku ili nemogućnosti pronalaska drugih njima relevantnih informacija, svoje odluke često temelje upravo na tome.

Kategorizacija proizvoda utječe i na način oblikovanja sadržaja osvrta, odnosno na što se fokusiraju pa tako Park i Kim (2008) razlikuju osvrte s fokusom na atribute te one fokusirane na koristi, a diferenciraju se prema tome što je temelj preporuke sadržane u osvrtu. Osvrti fokusirani na atribute pretežito su sačinjeni od tehničkih osobina proizvoda ili usluga, što znači da su subjektivne osobne preporuke autora osvrta temeljene na objektivnim podacima i opisima. Suprotno, osvrti s fokusom na koristi uključuju subjektivne interpretacije karakteristika proizvoda, a sukladno tomu ih i njihovi čitatelji, potencijalni kupci, mogu interpretirati.

5.2. Odnos potrošača i osvrta

U online okruženju svaki potrošač ima mogućnost izražavanja svog mišljenja i iskustva o određenom proizvodu ili usluzi, pružajući tako drugima informacije na kojima će temeljiti svoje odluke, a čime postaje informant i utjecajni sudionik (Lee i sur., 2007). Kao informant pruža informacije o proizvodu slične onima koje dolaze od proizvođača ili prodavača, ali iz perspektive potrošača. Razlika je u tome što proizvođači iznose tehničke podatke, na primjer materijali od kojih je proizvod sačinjen, specifikacije i tehničke standarde performansi, dok potrošač te iste podatke stavlja u kontekst konkretnog korištenja proizvoda i iskustva rukovanja istim. Kao utjecajni sudionik potrošač daje preporuku o proizvodu ili poduzeću, slično klasičnoj usmenoj predaji, koja sadrži subjektivna iskustva, mišljenja i usporedbe. Duan i sur. (2008) utjecaju osvrta pristupaju sa

stajališta samog njihovog sadržaja te diferenciraju efekte svjesnosti (eng. awareness effects) i efekte uvjeravanja (eng. persuasive effects). Korisnički osvrti prenose informaciju o postojanju određenog proizvoda, čineći ga tako dijelom izbora potencijalnog potrošača, a što predstavlja efekt svijesti. Nastavno, efekt uvjeravanja nastoji oblikovati stavove potencijalnih potrošača, kao i evaluaciju proizvoda.

Jedan od temelja utjecaja korisničkih osvrta može se pronaći u konformizmu, konstruktu koji opisuje tendenciju uspostavljanja grupne norme i nastojanja pojedinaca da se s istom poistovjete te u skladu s njom ponašaju (Lee i sur., 2008). Autori smatraju kako je razvidan primjer konformizma upravo donošenje kupovne odluke temeljem odluka drugih ljudi, što se događa zbog razmišljanja da je percipirani rizik kupovine manji ako velik broj pojedinaca donese istu odluku. Namjera ponašanja u skladu s većinom, odnosno konformizam dolazi iz interpersonalne prirode komunikacije, a naročito kada pojedinac prihvaća informacije proizašle iz takve interakcije kao dokaz o karakteristikama i kvaliteti proizvoda. Lee i sur. (2008) pozivajući se na postojeća istraživanja tvrde kako u slučajevima gdje postoji velik broj ljudi s istim mišljenjem, postoji i velika tendencija ponašanja u skladu s tim mišljenjem ili drugim riječima pojedinci su pod utjecajem većine. Značaj konformizma u ovom kontekstu se nadovezuje na ranije iznesene stavove o utjecaju relativne proporcije pozitivnih i negativnih osvrta na kupovnu namjeru.

5.3. Potencijalne poteškoće

Ludwig i sur. (2013) spominju potencijalni problem autentičnosti autora, odnosno radi li zaista o korisničkom osvrtu ili je određeno poduzeće, svjesno potencijala sustava osvrta, lažno se predstavljajući napisalo osvrt u nastojanju da poboljša prodaju svog proizvoda. Vodeći se sličnom logikom, Kusumasondjaja i sur. (2012) glavnim problemom smatraju anonimnost autora osvrta iz razloga što su jedini identifikatori online nadimak, dok su stvarno ime, slika ili bilo koji drugo osobno obilježje nedostupni, bilo da ih pružiti ne želi platforma za osvrte ili sami njihovi autori. Zbog dokazanog utjecaja usmene predaje, u njenom klasičnom i online obliku, na proces donošenja kupovne odluke i reputaciju, brojna poduzeća ulažu značajne napore u ”slušanje” online okruženja, a shodno tomu i reagiraju (Chatterjee, 2001).

Pitanje manipulacije osvrtima u cilju utjecaja na donošenje kupovne odluke potencijalnih potrošača nije hipotetski fenomen, navode Hu i sur. (2011), jer su poznati slučajevi u kojima izvori osvrta nisu bili autentični. Tako autori spominju slučaj Amazona kada su zbog softverske pogreške otkriveni identiteti autora osvrta novo objavljenih knjiga, a koji su mahom bili izdavači, sami autori

te njihovi prijatelji i obitelj. Također, postoje dokazi kako neka poduzeća i plaćaju korisnicima dijeljenje pozitivnih osvrta, a sve u svrhu utjecaja na percepciju i odluke potrošača (Chatterjee, 2001). Spomenuto je naročit problem u uslužnoj industriji, gdje se brojni restorani i hoteli upuštaju u plasman lažnih osvrta kako bi privukli goste, dok su s druge strane i najpodložniji aktivnostima konkurenata koji, lažno predstavljeni, ostavljaju izrazito negativne osvrte (Hu i sur., 2011). Problematičan je i sam obujam, raspon i raznovrsnost informacija o pojedinim proizvodima, uslugama i poduzećima, jer kako Chatterjee (2001) navodi, prosječnom je korisniku nemoguće pregledati sve dostupne osvrte temeljem kojih bi donio informiranu i nepristranu odluku.

5.4. Aktualni trendovi

Obzirom da je razvoj tehnologije omogućio korisničke osvrte u formi mnogi – prema – mnogima komunikacije, za očekivati je kako će o istome i ovisiti. Naime, dolazi do pojave novih platformi i mreža, novih funkcionalnosti u sklopu postojećih, koje uvijek unapređuju i rastuće dostupnosti, a sve u cilju privlačenja što većeg broja korisnika te posljedično, povećanja svog tržišnog udjela. Sukladno navedenom, kako bi se problematika mogla sagledati u svjetlu recentnih relevantnih podataka, korišteni su rezultati dvaju istraživanja provedenih od strane nezavisnih agencija Bright Local i Review Trackers. Bright Local je istraživanje proveo na uzorku od 1 031 građana SAD, članova ekspertnog panela, u listopadu 2017 godine. Istraživanje Review Trackers sastoji se od dva dijela - u prvom dijelu podaci su prikupljeni u periodu od četvrtog kvartala 2017. i prvog kvartala 2018. godine, na uzorku od 463 ispitanika građana SAD anketom od 32 pitanja. Drugi dio istraživanja odnosi se na trendove u distribuciji i karakteristikama osvrta u svim značajnim industrijama, a provedeno je analizom oko 9 milijuna osvrta na preko 100 stranica u proteklih 8 godina.

Od ispitanika koji prilikom donošenja odluke o kupnji informacije traže online, većina ih najviše vjeruje Facebooku i Yelpu, koji imaju po 20% .

Slika 4. Najpopularnije stranice s korisničkim osvrtima

Izvor: BrigtLocal

Čak je 68% ispitanika reklo da pozitivni osvrti utječu na njihovu odluku o korištenju usluge, odnosno kupovini od određenog poduzeća/trgovca, što je porast od 18 postotnih poena u odnosu na prethodnu, 2016. godinu. Navedeni je porast praćen padom utjecaja negativnih osvrta, s 68% u 2016. godini na 40% u promatranoj 2017.

Slika 5. Utjecaj korisničkih osvrta na donošenje odluke

Izvor: BrightLocal

U 2016. godini 50% ispitanika je izjavilo kako bi nakon čitanja pozitivnog osvrta posjetilo web stranicu poslovnog subjekta, dok je isto u 2017. izjavilo 37% ispitanika, međutim prisutan je

porast u odluci da se izravno posjeti poduzeće, na čak 17%, kao i čitanje dodatnih osvrta kako bi se potvrdio dobar izbor, što je izjavilo 26 % ispitanika u 2017.

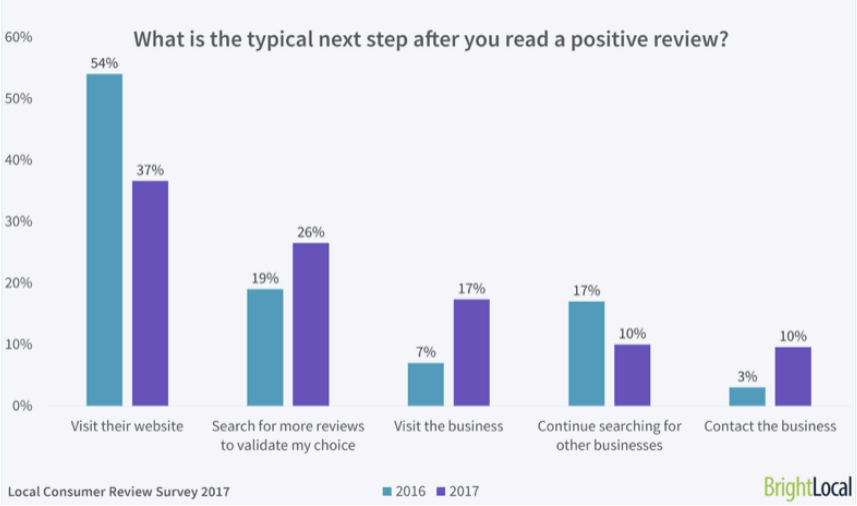

Slika 6. Koraci nakon čitanja korisničkog osvrta

Izvor: BrightLocal

93% ispitanika pretražuje korisničke osvrte kako bi odlučili radi li se o poduzeću s dobrom reputacijom, od čega čak 35% ispitanika prilikom procjene reputacije uvijek pregledava korisničke osvrte, a 31% redovito. Rezultati upućuju na izuzetan značaj reputacije u formiranju povjerenja te daljnjeg razmatranju određenog poslovnog subjekta u donošenju kupovne odluke.

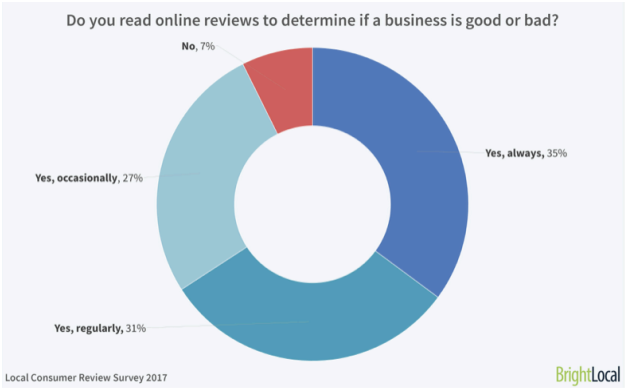

Slika 7. Čitanje korisničkih osvrta kao procjene poduzeća

Izvor: BrightLocal

Korisnički osvrti imaju utjecaj na povjerenje prema određenom poduzeću, a tomu u prilog idu i rezultati istraživanja prema kojima 73% potrošača izražava povećano povjerenje nakon čitanja pozitivnog osvrta. Zanimljivo je primijetiti da znatno manji udio potrošača, njih 50%, izjavljuje kako zbog negativnih osvrta dovode u pitanje kvalitetu određenog poduzeća, dok je u prethodnoj godini to izjavilo 60% ispitanika. Primjetan je i porast korisnika koji čitaju osvrte, ali smatraju kako ne utječu na odluku, s 21% na 24%, što potencijalno sugerira kako s normalizacijom korištenja interneta te konkretno korisničkih osvrta u evaluaciji, raste i samopouzdanje prosječnih korisnika, čime percepcija utjecaja osvrta opada. Naravno, moguće je i da je riječ o lažnom samopouzdanju te da su osvrti utjecajni na podsvjesnoj razini.

Slika 8. Utjecaj korisničkih osvrta na mišljenje o poduzeću

Izvor: BrightLocal

Porast značaja bilježi kvantiteta osvrta, koji je u 2017. godini bio drugi najčešći faktor na koji korisnici obraćaju pozornost i to njih čak 46%. Ocjena putem zvjezdica je najbitnije faktor za 54% ispitanika, 4% manje nego prethodne godine. Korisnici pak paze da su osvrti proizašli iz nedavnih transakcija, njih 38%, zbog relevantnosti, kao i na to odgovara li određeni poslovni subjekt na osvrte (30%). Dogodio se pomak u značaju sentimenta osvrta, odnosno njegovo smanjenje, od 47% u prethodnoj godini svega 32% korisnika obraća pozornost na ovu varijablu. Kada se navedeno uzme u obzir s prethodno spomenuto s visokim značajem sustava ocjenjivanja putem zvjezdica moguće je zaključiti kako potrošači traže način na koji mogu steći određeni dojam te formirati očekivanje o ishodu transakcije, a da je jednostavno i ne oduzima mnogo vremena.

Također, rezultati su u skladu i s teoretskim razmatranjima značaja prosječne ocjene putem zvjezdica, jer potencijalnom kupcu olakšavaju procjenu.

Slika 9. Karakteristike osvrta na koje se obraća pozornost prilikom čitanja

Izvor: BrightLocal

Zanimljivo je primijetiti kako većina poslovnih subjekata, njih 63,3% ne odgovara na osvrte svojih potrošača, iako preko polovice očekuje odgovor u roku od sedam dana, a skoro 45% njih navodi kako je vjerojatnost posjeta veća ukoliko dobiju odgovor. Stoga je moguće zaključiti kako je potrebno podići razinu svijesti poslovnih subjekata o imperativu odgovora na osvrte, jer rezultati upućuju kako bi od toga mogli profitirati.

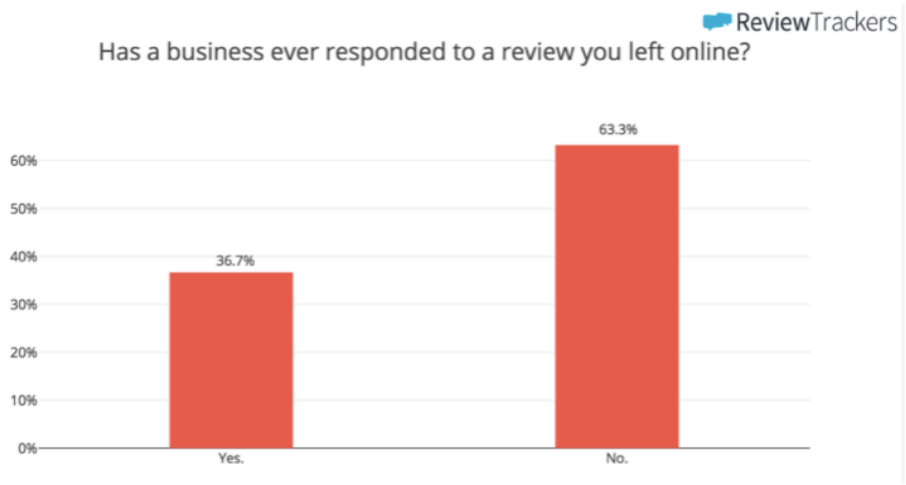

Slika 10. Odgovori poduzeća na osvrte

Izvor: ReviewTrackers

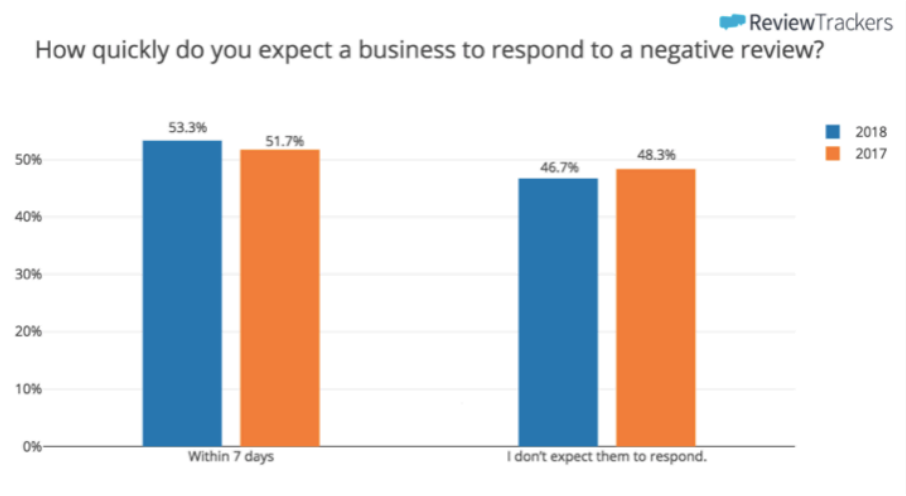

Slika 11. Očekivanja korisnika o odogovorima na osvrte

Izvor: ReviewTrackers

Četiri su osvrta dovoljna za formiranje povjerenja u poslovni subjekt za 68% ispitanika, a što upućuje da većina nastoji u relativno kratkom roku donijeti odluku. Ipak u porastu je broj korisnika koji pregledaju preko 11 osvrta prije formiranja povjerenja.

Slika 12. Broj pročitanih osvrta potrebnih za formiranje povjerenja

Izvor: BrightLocal

Odnos online osvrta i osobnih preporuka, odnosno sličnosti i razlike po pitanju formiranja povjerenja u određeni poslovni subjekt, pitanje je koje je donijelo zanimljive rezultate. Naime, 85% potrošača vjeruje online osvrtima jednako kao i osobnim preporukama, što je porast od jednog postotnog poena u odnosu na prethodnu godinu. Od toga 19% uvijek vjeruje online osvrtima kao i osobnim preporukama, dok je povjerenje ostalih korisnika uvjetovano faktorima kao što su procijenjena autentičnost osvrta (25%), tip industrije (20%) te broj osvrta (20%).

Značaj ovog pitanja proizlazi iz same naravi osobnih preporuka, odnosno usmene predaje, jer su prije razvoja interneta te suvremenih tehnologija interakcije i razmjena informacija bili ograničeni na nečiji društveni krug, dok danas svačije mišljenje može biti globalno. Samim time, povlači se pitanje povjerenja u autora osvrta, koje je prema rezultatima ovog istraživanja u interakciji s drugim, prethodno spomenutim faktorima u većini slučajeva na jednakoj razini s usmenom predajom.

Slika 13. Povjerenje u korisničke osvrte i osobne preporuke

Izvor: BrightLocal

Gotovo dvostruko više ispitanika je ostavilo pozitivni osvrt, čak 63%, naspram 35% ispitanika koji su ostavili negativan osvrt. Rezultati sugeriraju kako je pozitivno iskustvo, tj. zadovoljstvo proizvodom i uslugom veći motivator pisanja osvrta od negativnih, međutim još uvijek ostaje pitanje na što prosječni čitatelj osvrta više obraća pozornost, odnosno što ima veći utjecaj na donošenje odluke. Prema istraživanju provedenom od strane ReviewTrackersa 94,3% ispitanika je donijelo negativnu odluku nakon čitanja pretežito negativnih osvrta, a naročito ukoliko se osvrti nezadovoljnih korisnika protežu kroz više platformi. Vrijedi napomenuti i kako oko četvrtine ispitanika još uvijek nije napisalo nijedan osvrt, ali bi razmotrilo tu mogućnost te bi poduzeća ovu skupinu mogli motivirati kako bi dodatno kapitalizirala na pozitivnim iskustvima koja proizlaze iz njihova pristupa potrošačima.

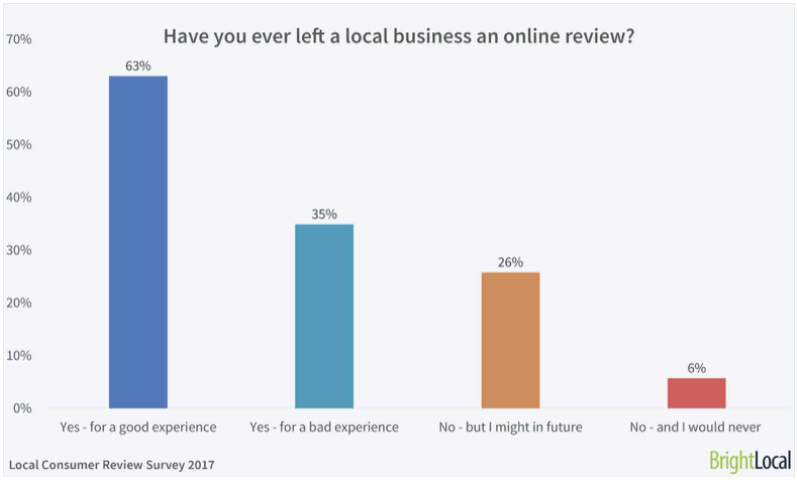

Slika 14. Učestalost pisanja korisničkih osvrta

Izvor: BrightLocal

Kako je prethodno bilo govora, rastući udio potrošača kao utjecajan faktor prilikom formiranja mišljenja o poduzeću smatra odgovor na osvrt (Slika 10.) pa se problem lažnih negativnih komentara od strane konkurencije može ovim putem značajno umanjiti. Pitanje je, međutim, može li prosječan potrošač prepoznati lažni osvrt, bio on pozitivan ili negativan, a rezultati su pokazali kako ih svega 16% ispitanika može uvijek uočiti. Čak je 79% ispitanika pročitalo lažni osvrt u prethodnoj godini, od čega je 25% pročitalo mnogo, dok se 54% izjasnilo kako ih je pročitalo nekoliko. Međutim, treba napomenuti kako su rezultati istraživanja podložni sposobnosti zapažanja korisnika, njihovom samopouzdanju i povjerenju, odnosno nedostatku istih. Obzirom na aktualnost fenomena lažnih vijesti (eng. fake news), moguće je pretpostaviti kako će skepticizam potrošača u narednom periodu još porasti, a što predstavlja otegotnu okolnost za sve djelatnosti. Naime, za one subjekte koji se oslanjaju na pozitivna iskustva svojih potrošača u privlačenju novih, primjerice restorane, općeniti nedostatak povjerenja u sustav osvrta i ocjena znači potrebu većeg angažmana u praćenju istog te motiviranje korisnika u ostavljanje pozitivnih osvrta, što za sobom vodi i povišene troškove poslovanja kroz trošak osoblja zaduženog za spomenuto, ali i trošak motivacije potrošača (npr. u slučaju restorana to je uglavnom besplatno piće ili desert, vaučeri ili popust).

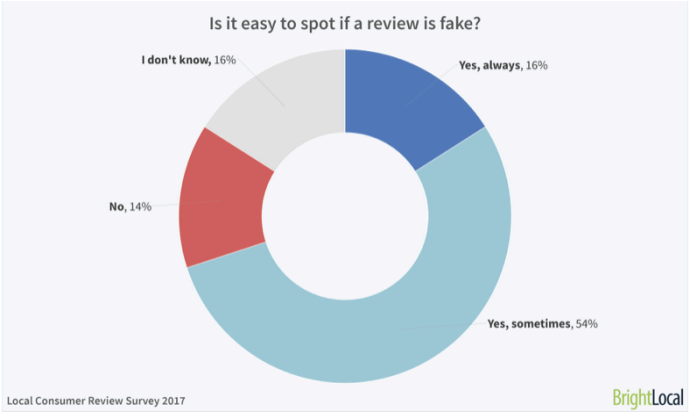

Slika 15. Mogućnost primjećivanja lažnih osvrta

Izvor: BrightLocal

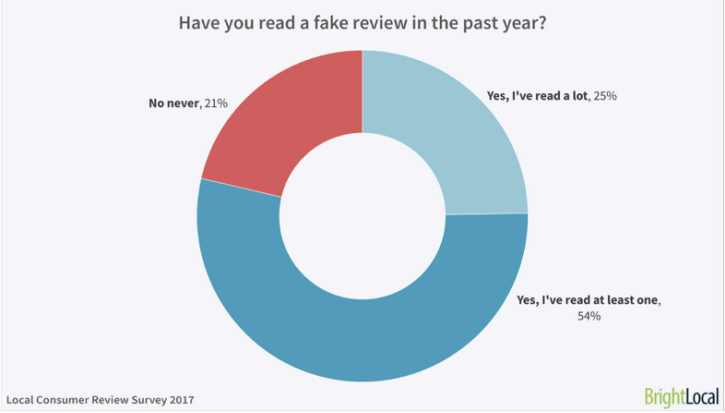

Slika 16. Učestalost lažnih osvrta

Izvor: BrightLocal

Google je stranica izbora kada je riječ o posjetu stranica prilikom donošenja odluke o posjeti određenog poslovnog subjekta, s čak 63,64% ispitanika. Ipak, navedeno treba uzeti s rezervom, obzirom da je Google najkorištenija tražilica gdje se prilikom pretraživanja određenog subjekta zajedno s rezultatima prikaže i relativna ocjena s osvrtima, što sa stajališta prosječnog korisnika prikladno i zahtijeva manje koraka i vremena.

Slika 17. Stranice na kojima se najčešće čitaju korisnički osvrti

Izvor: ReviewTrackers

Potrošači najviše vjeruju, odnosno najvjerodostojnijom smatraju ocjene od četiri zvjezdice, iako manjem omjeru nego prethodne godine. S druge strane, vidljiv je porast povjerenja u ocjene od jedne zvjezdice što upućuje na zaključak kako potrošači nastoje steći cjelovitu sliku o određenom subjektu, kako pozitivne strane, tako i negativne, a kako bi se pripremili na sve potencijalne ishode**.** Većina stranica pruža i mogućnost filtriranja osvrta prema kriteriju prosječne ocjene, a postaje sve važnije jer je u 2018. godini 70% potrošača filtriralo što je nezanemariv porast na 40% u prethodnoj godini. Najčešći kriterij u promatranoj godini je prosječna ocjena od četiri zvjezdice, što znači da oni poslovni subjekti, neovisno o djelatnosti, ukoliko imaju manju ocjenu od navedene, jednostavno ne ulaze u daljnje razmatranje.

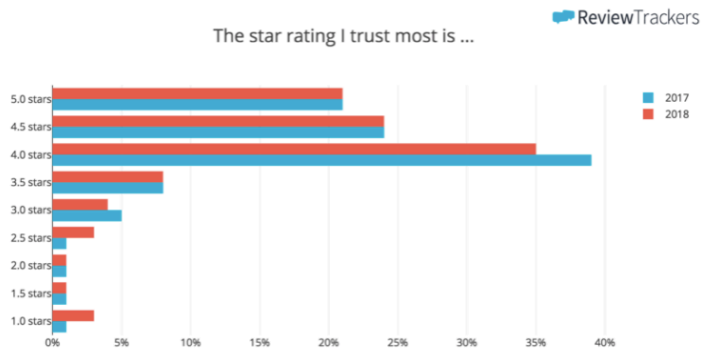

Slika 18. Prosječna ocjena kojoj korisnici najviše vjeruju

Izvor: ReviewTrackers

U proteklih osam godina osvrti su postali oko 65% kraći, dok su u 2010. godini u prosjeku sadržavali oko 600 znakova, danas otprilike imaju nešto iznad 200 znakova, a do čega je došlo zbog nekoliko razloga. Prvi se odnosi na potrošače i njihovo shvaćanje pojma osvrta, koji više nije, kao prije pet godina, cjeloviti prikaz karakteristika i korištenja nekog proizvoda od nekoliko paragrafa, već se radi o jednoj ili nekoliko rečenica u kojima je koncizno sažeto ono što je iz perspektive korisnika bitno. Dakle, potrošači pišu onakve osvrte kakve i sami žele čitati. Drugi razlog leži u samoj tehnologiji, napose mobilnim uređajima s kojima svaki korisnik u svakom trenutku može pristupiti internetu i društvenim mrežama. Naročito u SAD – u, uz popularnost društvene mreže Twitter, postalo je uobičajeno iskazati svoje mišljenje uz ograničeni broj znakova, a što se zrcali i na ostale društvene mreže.

Slika 19. Promjena duljine korisničkih osvrta 2010 – 2017

Izvor: ReviewTrackers

Također je primjetan pomak i u tome gdje se osvrti ostavljaju, gdje je vidljivo kako Google uzima udio stranicama namijenjenih isključivo osvrtima (Yelp, TripaAdvisor), a razlog tomu je prethodno navedena jednostavnost i prikladnost za prosječnog korisnika. U prethodnoj godini Google i Facebook zajedno drže gotovo 80% udjela korisničkih osvrta, a činjenica da se osvrti u najvećoj mjeri ostavljaju na društvenim i pretraživačkim mrežama posljedično potrošaču onemogućava bilo kakvo informiranje o proizvodu ili poduzeću bez da je prvo izložen mišljenju i iskustvima drugih korisnika.

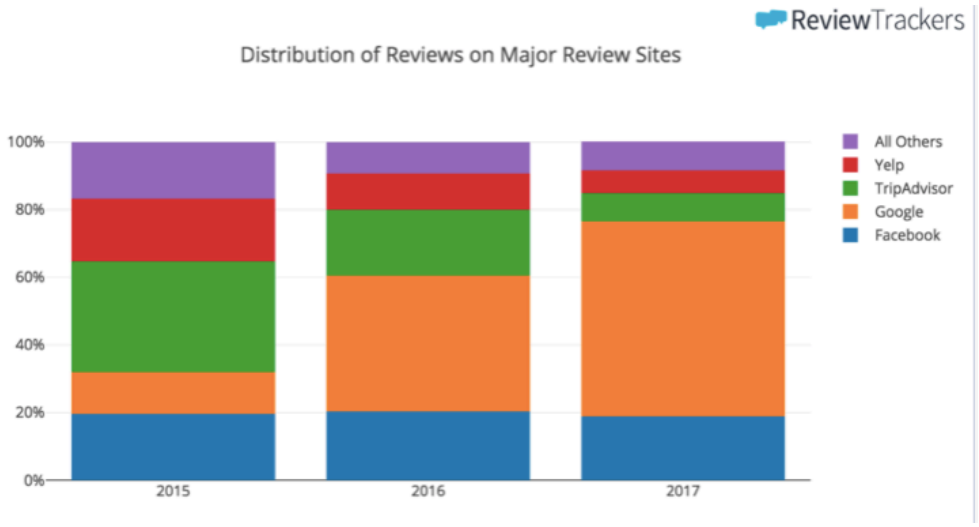

Slika 20. Distribucija korisničkih osvrta prema platformama 2015 – 2017

Izvor: ReviewTrackers

Također je vidljiv trend sve pozitivnijih osvrta, koji je od 2010. godine porastao za 12% (Review Trackers, 2018). Navedeno se može dovesti u vezu s porastom Googlea i Facebooka u ukupnoj distribuciji osvrta, obzirom da osvrti na te dvije mreže imaju i najveće prosječne ocjene, odnosno najveći broj pozitivnih osvrta, Facebook 4,42, a Google 4,3. Prosječni korisnik najviše vremena kojeg provodi online, u pravilu provodi upravo na ove dvije mreže, koje pružaju mogućnost jednostavnog dijeljenja osvrta na svojim profilima, uslijed čega je moguće zaključiti kako postoji pozitivna korelacija između sentimenta osvrta i jednostavnosti njegova dijeljenja, dakle vjerojatnost dijeljenja pozitivnog iskustva je veća što ga je lakše podijeliti.

Slika 21. Promjena prosječne ocjene kroz vrijeme

Izvor: ReviewTracker

6. Povjerenje

6.1. Teoretske odrednice

Povjerenje ima ključnu ulogu u prevladavanju osjećaja nesigurnosti te smanjenju percipiranog rizika (McKnight i sur., 2002) iz čega proizlazi kako je povjerenje jedan od temeljnih čimbenika uspostavljanja odnosa. U kontekstu trgovinskih transakcija, u čijem je fokusu odnos između kupca i prodavača, gdje postoji izvjestan stupanj rizika s obje strane, povjerenje dodatno dolazi do izražaja (Gefen i sur, 2003). Obzirom na značaj, razumljiv je interes istraživača u pokušaju njegova definiranja te uspostavljanju jedinstvene tipologije koja bi daljnja istraživanja i nastojanja razumijevanja utjecaja povjerenja pojednostavnila. Ipak, povjerenje je kao konstrukt teško definirati i izmjeriti te su postojala različita stajališta, kako McKnight i sur. (2002) navode, pa je tako prethodno prevladavalo uvjerenje kako je riječ o unitarnom konceptu, dok se danas ipak većina istraživača slaže kako je riječ o multidimenzionalnom konceptu, koji kao takav zahtijeva krosdisciplinski pristup. U današnje vrijeme, uzevši u obzir razvoj tehnologije koji je omogućio brzu razmjenu informacija, rezultata istraživanja te znanstvenih spoznaja, porast broja izvora podataka te mogućnosti prikupljanja i analize istih, ne čudi što Mukherjee i Nath (2007) smatraju kako povjerenje inkorporira ideje ekonomije, marketinga, sociologije, psihologije, organizacijskog ponašanja, strategije, informacijskih sustava te znanosti odlučivanja.

U skladu s navedenim, javila su se različita nastojanja da se definira povjerenje pa tako McKinght i sur. (2002) iznose kako je u psihologiji povjerenje definirano kao sklonost vjerovanja drugima, društvena ga psihologija definira kao spoznaju o partneru u odnosu, dok je u sociologiji prevladavajući pristup kako je riječ o karakteristikama institucionalne okoline. Većina autora (Mukherjee i Nath, 2007; McKnight i sur, 2004; Shankar i sur, 2002; Bart i sur, 2005; Gefen i sur, 2003) se referira na definiciju koju su iznijeli Rousseau i sur (1998) prema kojima je povjerenje ”*psihološko stanje koje sadrži namjeru prihvaćanja ranjivosti temeljenu na pozitivnim očekivanjima namjere ponašanja druge strane*”. Alternativno, Zand (1972, citiran u Fairley i sur, 2014) definira povjerenje kao spremnost subjekta na povećanje vlastite ranjivosti uslijed ponašanja druge strane nad kojim nema kontrolu. Shankar i sur. (2002) nastoje pojednostaviti konstrukt povjerenja koristeći se razmatranjima Luhmana (1979) te navode kako je povjerenje zapravo vjerovanje jedne strane o ponašanju druge strane, odnosno da će se druga strana ponašati na predvidljiv način. Garbarino i Johnson (1999) razmatrajući povjerenje koriste se i definicijom Morgana i Hunta (1994) prema kojoj je povjerenje postavljeno kao percepcija uvjerenja u

pouzdanost i integritet partnera u razmjeni, dok Mukherjee i Nath (2007) u kontekstu kupoprodajnog odnosa navode pragmatičnu definiciju Spekmana (1988) prema kojem je povjerenje temelj strateškog partnerstva između kupca i prodavača. Nekoliko je koncepata oko čije se neupitne važnosti istraživači slažu, koji su podložni različitim interpretacijama, a posljedično i istraživačkim implikacijama, ovisno o polazištu njihova razmatranja. Ti su koncepti dvosmjerni, odnosno u međusobnoj su interakciji, prvi je postojanje dviju strana, zatim ranjivost jedne strane te očekivanje o namjeri ponašanja druge strane.

Svaki pojedinac intuitivno već razumije važnost povjerenja, međutim kojim mehanizmima djeluje na percepciju okoline i odnose te kako zapravo utječe na namjere i ponašanje? Gefen i sur. (2003) smatraju kako povjerenje proizlazi iz duboko ukorijenjene ljudske potrebe za razumijevanjem svoje društvene okoline, odnosno potrebe za identificiranjem što, kada, kako i zašto drugi čine, odnosno zašto se ponašaju na način na koji jesu. Društvenu okolinu čine ljudi i njihova djelovanja koja nisu nužno racionalna i predvidljiva, zbog čega je ona izuzetno kompleksna i gotovo nemoguća za cjelovito shvaćanje, što je u protutezi sa spomenutom ljudskom težnjom za razumijevanjem iste. Autori navode razmatranja Luhmanna (1979) prema kojem u situacijama kada društveno okruženje ne može biti regulirano pravilima i običajima, ljudi prihvaćaju povjerenje kao središnju strategiju smanjenja kompleksnosti. Prema toj strategiji, iz povjerenja proizlazi vjer ovanje, koje možda i jest ponekad iracionalno, a koje umanjuje percepciju rizika od nepovoljnog, ali ipak mogućeg ishoda – budućeg ponašanja partnera u odnosu/interakciji. Dakle, strana koja vjeruje je uvijek suočena s mogućnošću, tj. rizikom, da njeno povjerenje neće biti opravdano (Fairley i sur., 2014). Drugim riječima, odluka o povjerenju uključuje stratešku nesigurnost, pri čemu se formira relativno očekivanje rizika neispunjenja povjerenja, odnosno nepovoljnog ishoda, a temeljem čega se donosi odluka o tome vjerovati ili ne. Na tom su tragu i Koufaris i Hampton – Sosa (2003) koji su kao determinirajuće koncepte povjerenja naveli nesigurnost vezanu uz potencijalni ili postojeći odnos (poslovni ili društveni), a koja vodi do drugog koncepta – određenog stupnja percipiranog rizika, odnosno ranjivosti. Autori temelje svoje zaključke na prethodnim istraživanjima Mayera i sur. (1995) prema kojima percipirani rizik proizlazi iz vjerovanja o partnerovoj sposobnosti, integritetu i benevolentnosti. S druge strane, Geyskens i sur. (1996) referiraju se na zaključke istraživanja iz područja društvene psihologije koja kao odrednice povjerenja predstavlja dva koncepta – povjerenje u partnerovo poštenje te povjerenje u partnerovu benevolentnost. Iz navedenog proizlazi da se povjerenje formira iz percepcija partnerove

sposobnosti, tj. stručnosti da isporuči ono što je obećano unutar odgovarajućih parametara, procjene partnerovog karaktera te sukladnosti istih i u konačnici, vjerovanja u želju za dobrobiti svih uključenih u odnos/interakciju.

6.2. Što prethodi povjerenju

Povjerenje je, kako je prethodno bilo govora, kompleksan pojam sastavljen od niza činitelja koji su u međusobnoj interakciji te ga se, zbog lakšeg shvaćanja i razumijevanja, može promatrati kao proces. Prateći tu analogiju slijedi da, kao i svaki drugi proces, ima svoj početak, odnosno bazu na kojoj se temelji ili pretprocese, ali i da nije statičan pojam već se pod utjecajem brojnih činitelja razvija te ima svoj ishod, bio on konačan ili ne. Značaj povjerenja proizlazi iz njegove uloge u nadvladavanju osjećaja nesigurnosti i rizika, a samim time pruža poticaj pojedincima da se upuste u odnose i transakcije nad kojima nemaju kontrolu što neizbježno znači neizvjesne ishode. Stoga je bitno, naročito u poslovnom kontekstu, identificirati koji su to činitelji koji prethode povjerenju, a kako bi se potencijalne kupce potaklo na ”prvi korak”.

Gefen i sur. (2003) su iznijeli pet prethodnika povjerenja: *povjerenje temeljeno na znanju, institucijsko povjerenje, kalkulativno povjerenje, kognitivno povjerenje te povjerenje proizašlo iz osobnosti pojedinca*. *Povjerenje temeljeno na znanju* se, prema autorima, temelji na iskustvu o tome tko, što, kako i kada se događa što samo po sebi umanjuje društvene neizvjesnosti kroz povećan stupanj razumijevanja o trenutnim događajima. Nadalje se referiraju na Doneyja i sur (1998) koji ovaj tip činitelja promatra kao proces predviđanja u kojem osoba koja se upušta u odnos temelji svoje povjerenje na vlastitoj sposobnosti da predvidi ponašanje druge strane. *Institucijsko povjerenje* se odnosi na okolinu unutar koje se odnos ili transakcija odvija, tj. odgovara li okruženje onome što pojedinac smatra tipičnim i očekivanim. U tom smislu se navode McKnight i sur. (1998) koji definiraju dva podtipa ovog činitelja: situacijsku normalnost, kao procjenu uspjeha transakcije ovisno o uobičajenosti situacije te strukturna uvjerenja koji predstavljaju procjenu uspjeha kroz sigurnosne mreže kao što su pravni uvjeti, garancije i regulacije koje postoje u određenom kontekstu. *Kalkulativno povjerenje* se, kako i sam naziv sugerira, temelji na kalkulaciji troška i koristi, tj. njihova odnosa. U ovom smislu autori navode razmatranja Doneyja i sur. (1998) i Williamsona (1985) prema kojima se stajalište o povjerenju derivira iz ekonomske analize tekućih odnosa, preciznije na procjeni isplativosti druge strane da se upusti u oportunistička ponašanja. Dakle, ukoliko pojedinac procjeni da druga strana nema što dobiti nepoštenim ponašanjem ili prevarom, odnosno ukoliko joj prijete određene sankcije, tada se donosi zaključak da će ishod

transakcije biti povoljan. *Kognitivno povjerenje* proizlazi iz prvog dojma te kategorizacije i iluzije kontrole. Razumno je konstatirati, temeljem same ljudske prirode, kako će osoba pružiti svoje povjerenje drugoj strani ukoliko prema prvom dojmu zaključi kako joj je ona slična, što je sukladno razmatranjima Kim i sur. (2008) prema kojima je kognitivno povjerenje povezano s karakteristikama druge strane. Tim tijekom razmišljanja dolazi se do toga da će osoba, u nedostatku informacija iz prve ruke, procjenu o pouzdanosti donijeti temeljem sličnosti s drugom stranom, što vodi do iluzije kontrole nad situacijom, a koja može biti i neopravdana. *Povjerenje proizašlo iz osobnosti pojedinca* se odnosi na pojedinčeve osobine koje vode do očekivanja pouzdanosti, zatim na sklonost prema vjeri u humanost te stavu prema drugima (Kim i sur., 2008). Gefen i sur. (2003) smatraju ovaj tip povjerenja signalom prije samog iskustva, a iz kojeg mogu proizaći racionalnije procjene.

Primjenjujući dostupna istraživanja o povjerenju u online kontekstu, Kim i sur. (2008) uz povjerenje temeljeno na osobnosti te kognitivno povjerenje izdvajaju *afektivno* i *iskustveno povjerenje*. *Afektivno povjerenje* se odnosi na uvjerenje kako postoji sigurnost transakcije garantirana od treće strane, a čija je svrha smanjiti razinu percipiranog rizika te uvjeriti potencijalne kupce kako će se njihovim podacima raspolagati na etičan i propisan način, ali i da postoje odgovarajući sustavi upravljanja prigovorima, zamjene proizvoda u slučaju nezadovoljstva i tako dalje. U ovom kontekstu autori navode i procjenu pozitivne reputacije druge strane, jer potencijalnu kupci smatraju kako prodavač osjeća obvezu prvenstveno prema samom sebi iz čega dalje proizlaze zaključci o njegovoj pouzdanosti. *Iskustveno povjerenje* se odnosi na upoznatost s prodajnim subjektom i razumijevanje relevantnih procedura kao što su traženje proizvoda i informacija te online naručivanja. Dakle, ukoliko osoba već ima iskustva s online kupovinom, pretpostavka je da stoga i poznaje način na koji može doći do željenog proizvoda pretragom kataloga, ali i do svih ostalih potrebnih informacija kao što su karakteristike proizvoda, rok dostave, politika povrata, garancije kvalitete i slično te da iskustvo transferira u eventualne kupovine s drugih online ponuditelja. Kim i sur. (2008) smatraju kako je u ovom kontekstu važno razmotriti i ulogu upoznatosti, tj. iskustva, u smanjenju percipiranog rizika te prevladavanju kompleksnosti i neizvjesnosti.

Polazeći od teorije privrženosti – povjerenja, Mukherjee i Nath (2007) identificirali su pet glavnih činitelja što prethode povjerenju: *zajedničke vrijednosti, komunikacija, oportunističko ponašanje, privatnost i sigurnost*. Autori se pozivaju na Morgana i Hunta (1994) u definiranju

zajedničkih vrijednosti, prema kojima one predstavljaju mjeru u kojem partneri dijele stavove o tome koja su ponašanja, ciljevi i politike važne ili nevažne, ispravne ili neispravne, odnosno što je etično ili neetično. *Komunikacija* je formalno i neformalno dijeljenje smislenih i pravovremenih informacija (Anderson i Narus, 1990; citirani u Mukherjee i Nath, 2007) te kao takva može djelovati u smanjivanju neizvjesnosti, dvojbi, rješavanju konflikata te svih drugih eventualnih poteškoća. *Oportunističko ponašanje* autori definiraju referirajući se na Williamson (1975), a prema kojemu ono proizlazi iz teorija transakcijskih troškova, odnosno predstavlja djelovanje u vlastitom interesu s namjerom prevare. Procjena integriteta prodavača, naročito u uvjetima neizvjesnosti i rizika koji prevladavaju u online okruženju, je dakle od izuzetnog značaja u formiranju povjerenja (Mukherjee i Nath, 2007). *Privatnost* se, prema autorima, odnosi na pitanja zaštite podataka koji mogu identificirati pojedinca, a koji su dostupni na internetu. Za očekivati je da postoje sumnje u efikasnost sustava za zaštitu privatnosti obzirom da je riječ o nečem neopipljivom i, za tehnološki prosječno pismenu osobu, teško shvatljivom u smislu mehanizama djelovanja. Navedeno tim više dolazi do izražaja u online okruženju jer postoji shvaćanje interneta kao okoline u kojoj su izvjesna djelovanja pod velom anonimnosti koja pruža osjećaj sigurnosti i slobode u izražavanju i ponašanju. Spomenuto vodi do petog, posljednjeg činitelja kojeg Mukherjee i Nath (2007) smatraju prethodnikom povjerenja – *sigurnosti*. Pitanje sigurnosti se odnosi na praktične implikacije transakcija u online okruženju, preciznije uvjerenje da se upuštanjem u istu ne ispunjava rizik npr. virusa na računalu, ukradenog broja kartice ili prijenosa novca na neželjeni račun.

Vidljivo je kako je izučavanje prethodnika povjerenja kompleksno te se činitelji razlikuju ovisno o tome s kojeg se stajališta istražuje. Ipak, moguće je uočiti i sličnosti u predstavljenim modelima. Tako višestruki izvori, u različitim tipologijama, definiraju povjerenje temeljeno na osobnosti i kognitivno povjerenje (Gefen i sur., 2003; Kim i sur., 2008) kao činitelje koji prethode povjerenju. Preklapanja čak nadilaze uključivanje istih činitelja te se nalaze sličnosti među ponuđenim tipologijama, gdje su razvidne poveznice između kalkulativnog povjerenja (Gefen i sur., 2003) i oportunističkog ponašanja (Mukherjee i Nath, 2007) koji se odnose na procjenu troška – koristi nepoštenog ponašanja druge strane u odnosu/transakciji kao temelja odluke o samom povjerenju. Nadalje, pitanja privatnosti i sigurnosti (Mukherjee i Nath, 2007) se mogu usporediti s pojmom institucijskog povjerenja (Gefen i sur., 2003), kao uvjerenja osobe, potencijalnog kupca, da im je okolina u kojoj se odvija transakcija predvidljiva, normalna te da udovoljava normama

sigurnosti i (poslovne) etičnosti. Također, postoje poveznice između povjerenja temeljenog na znanju (Gefen i sur., 2008) i iskustvenog povjerenja (Kim i sur., 2008) jer oba pristupa podrazumijevaju poznavanje ili makar iluziju poznavanja okoline transakcije i njenih ishoda. Moguće je usporediti i zajedničke vrijednosti, koje navode Mukherjee i Nath (2007) te kognitivno povjerenje (Gefen i sur., 2003) gdje oba pojma podrazumijevaju donošenja odluke o pružanju povjerenja obzirom na prvi dojam i procjenu sličnosti s drugom stranom.

6.3. Povjerenje – mehanizmi djelovanja i tipologija

6.3.1. Inicijalno povjerenje

U svom istraživanju o formiranju povjerenja potencijalnih kupaca u online trgovine Koufaris i Hampton – Sosa (2003) fokus stavljaju na inicijalno povjerenje. Naime, iako autori prepoznaju povjerenje kao dinamični proces koji je pod utjecajem konstantnih interakcija između uključenih strana, smatraju kako se ono ipak može formirati i bez prethodnog iskustva ili interakcije. U tom smislu, definiraju *inicijalno povjerenje* kao spremnost na oslanjanje na nepoznatu stranu prije prve interakcije s njom. Dakle, inicijalno je povjerenje usmjereno prema strani o kojoj osoba ne posjeduje relevantne informacije, drugim riječima radi se o odnosu u kojem uključene strane nemaju pouzdane, smislene informacije jedna o drugoj, a ni uspostavljene društvene, afektivne veze (Bigley i Pierce, 1998, citirani u McKnight i sur., 2002).

Formiranje inicijalnog povjerenja svoje temelje ima u kognitivnom povjerenju, smatraju McKnight i sur. (2002), zbog, kako je prethodno bilo govora, društvenih kategorizacija, reputacije, iluzija te sličnosti među uključenim stranama. Ovaj je tip povjerenja naročito značajan u online okruženju, gdje postoje brojni akteri te visoka vjerojatnost pronalaska novih transakcijskih partnera, ali i dokazuje procesnu narav povjerenja upravo zbog svoje, jednostavno rečeno, kratkotrajnosti. McKnight i sur. (2004) navode kako poduzeća koja svoje poslovanje temelje na internetu moraju poduzeti napore u kreiranju okoline koja će izazvati pozitivan prvi dojam te posljedično inicijalno povjerenje. Autori identificiraju dvije faze, uvodnu i eksplorativnu, gdje prvospomenuta podrazumijeva izostanak iskustva korisnika koji se još uvijek oslanja na informacije iz druge ruke, a potonja se odnosi na onaj trenutak kada korisnik konačno posjeti web stranicu, nakon čega se upušta u proces donošenja odluke o tome treba li poduzeti transakciju s tim poduzećem ili ne. U uvodnoj fazi se korisnik oslanja na neiskustvene informacije koje su došle od drugih, bilo da se radi o web stranicama, surfanju, osvrtima i komentarima drugih kupaca ili oglašavanju (McKnight i sur., 2004). Eksplorativna faza, s druge strane, podrazumijeva da je

potencijalni kupac došao do izvjesnih informacija o poduzeću vlastitim pretraživanjem, a autori navode kako je karakterizirana upravo procjenom rizika transakcije temeljem ograničenih informacija.

6.3.2. Modeli povjerenja

Nakon inicijalne faze povjerenje se razvija te su raspoloživi modeli koji nastoje prepoznati komponente i utjecajne čimbenike, kao i ishode povjerenja. Koufaris i Hampton – Sosa (2003) spominju generički model povjerenja koji se sastoji od dvije temeljne komponente: *povjerenje u drugu stranu* te *kontrolne mehanizme koji osiguravaju uspješnost ishoda.* Naravno, generički model ne daje dovoljno dubok uvid u sam proces, već samo naznačuje potencijalni smjer u kojem bi istraživanja trebala krenuti. Dakle, kategorizacija i implikacije povjerenja polaze od internih čimbenika koji na isti utječu s jedne i eksternim čimbenicima s druge strane.

Na tom tragu su i Bart i sur. (2014) koji nastoje pronaći model izgradnje povjerenja u kontekstu online trgovine, a u čijem je fokusu povjerenje u web stranice te su stoga promatrali interakciju karakteristika web stranica, kao eksternih čimbenika, i karakteristike potrošača u web kontekstu, a rezultatom, tj, ishodom smatraju namjeru ponašanja. Kao karakteristike web stranica autori su odabrali privatnost, sigurnost, navigaciju i prezentaciju, snagu branda, pružanje savjeta, ispunjavanje narudžbe, obilježja zajednice i odsutnost pogreške, a kao osobne čimbenike upoznatost s web stranicom, ekspertizu u korištenju interneta te iskustvo u online kupovini. Privatnost i sigurnost se odnose na adekvatno rukovanje osobnim podacima, podacima o kreditnoj kartici te garanciju uspješnog i sigurnog plaćanja. Navigacija i prezentacija se odnose na izgled, položaj pojedinih informacija, slika, klikova na web stranici, a riječ je o značajnoj karakteristici web stranice online trgovine, jer determinira brzinu i lakoću pronalaska željenih predmeta upravo iz razloga što korisnici stranice koje im to omogućavaju percipiraju kao vjerodostojne. Snaga branda je zapravo simbol kvalitete te čimbenik u izgradnji povjerenja, posebno u situaciji kada nema mnoštvo dostupnih informacija, a autori također smatraju kako je njena važnost izražena kod proizvoda s visokim stupnjem uključenosti potencijalnog kupca. U pravilu, online trgovine nude mnoštvo proizvoda raspoređenih u niz kategorija te kupac može osjetiti poteškoće u pronalasku adekvatnog odabira, stoga one trgovine koje nude savjete i smjernice za sužavanje izbora imaju viši stupanj percipirane vjerodostojnosti, a naročito za one potencijalne transakcije s visokim percipiranim rizikom (Bart i sur., 2014). U procjeni transakcijske sposobnosti online trgovine, kako navode autori, značajna je mogućnost ispunjavanja narudžbe, koja je zapravo ključni faktor u

konceptu online trgovine. Sljedeća karakteristika web stranice u izgradnji modela povjerenja su obilježja zajednice koje Bart i sur. (2014) definiraju kao priliku za interakciju s drugim kupcima/korisnicima u chat grupama, online forumima, komentarima ispod proizvoda i slično, a značajnu ulogu u modelu imaju u situacijama visokog stupnja neizvjesnosti zbog dijeljenja i prikupljanja podataka, jer zajednička svijest i osjećaj moralne odgovornosti kroz razmjenu informacija i dijeljenje znanja zapravo pojačavaju povjerenje. Posljednja karakteristika web stranice u ovom modelu je odsutnost pogrešaka koju korisnik procjenjuje temeljem iskustva u korištenju stranice, odnosno je li web stranice reagirala na njegove akcije na adekvatan način ili ne. S druge strane, autori promatraju osobne karakteristike u online kontekstu koje su značajne u modelu izgradnje povjerenja, gdje upoznatost s web stranicom implicira kako će korisnik s pozitivnim prethodnim iskustvom izgledno razviti viši stupanj povjerenja. Osobna stručnost u korištenju interneta djeluje kroz samopouzdanje korisnika koje pruža stupanj sigurnosti u korištenje stranice i izvjesnost transakcije te samim slijedom proizlazi da korisnici s većim poznavanjem web stranice imaju i veći stupanj povjerenja u istu. U konačnici, iskustvo u online trgovini pomaže korisnicima u nadvladavanju osjećaja rizika i nesigurnosti potencijalne transakcije pa je razumno zaključiti da će korisnici s prethodnim iskustvom online kupovine imati i veće povjerenje u određenu web stranicu, a koja može i ne mora biti ona s kojom su prethodno imali iskustva. Temeljni ishod povjerenja prema ovom modelu je *namjera ponašanja* koja, prema Bart i sur. (2014), može uključivati spremnost na izvršavanje zadataka, kao što je klikanje kroz stranicu, napuštanje ili vraćanje na stranicu, slanje e-maila, preuzimanje datoteka ili ispunjavanje narudžbe. Autori također navode kako utjecaj povjerenja može biti izraženiji za određene kategorije proizvoda pa tako potencijalni kupci prolaze kroz duži proces donošenja odluke za one proizvode koje ne kupuju često, zatim s visokim stupnjem uključenosti, odnosno visokorizičnih proizvoda.

McKnight i Chervany (2001) te McKnight i sur. (2002) predstavljaju model povjerenja s dva utjecajna čimbenika: *institucionalnim povjerenjem* te *dispozicijom povjerenja*; i s tri međusobno povezana ishoda: *mišljenje o povjerenju*, *namjere povjerenja* te *ponašanja povezana s povjerenjem*, a cijeli model promatraju kroz četiri kategorije: *benevolenciju, integritet, kompetencije* te *predvidljivost*. Autori definiraju namjeru povjerenja kao spremnost ili namjeru osobe da ovisi o drugoj strani s osjećajem relativne sigurnosti, usprkos nedostatku kontrole nad njom i iako postoji vjerojatnost negativnih posljedica. Dvije su sastavnice namjere povjerenja: spremnost korisnika da ovisi, kao pripremljenost na činjenicu kako postaje ranjiv u odnosu s

drugom stranom, te vjerojatnost zavisnosti, kao osobna pretpostavka izvjesnosti neravnopravnog odnosa s osjećajem relativne sigurnosti. Praktične implikacije u kontekstu online trgovine su, prema McKnight i sur. (2002), tri vida specifičnog rizičnog ponašanja, pružanje osobnih informacija online trgovcu, upuštanje u kupovnu transakciju te djelovanje prema naputku online trgovca. Ponašanja povezana s povjerenjem, odnosno ona koja iz istog proizlaze predstavlja svojevoljnu zavisnost o drugoj osobi, bez osjećaja nesigurnosti, iako postoji mogućnost negativnog ishoda, a prema McKnightu i Chervanyju (2001) ima nekoliko pojavnih oblika: kooperacija, dijeljenje informacija, neformalni dogovori, smanjenje kontrole te dozvola utjecaja. Dakle, svako ponašanje povezano s povjerenjem se odvija s rizikom i nemogućnošću ili nedostatkom želje, za kontrolom druge strane. U kontekstu online trgovine primjeri ponašanja povezanih s povjerenjem uključuju dijeljenje osobnih informacija, kupovinu ili djelovanje prema sugestiji web stranice (McKnight i sur., 2002). Mišljenje o povjerenju predstavlja, kako McKnight i Chervany (2001) navode, mjeru u kojoj pojedinac vjeruje, s osjećajem relativne sigurnosti, kako druga strana ima za njega korisne karakteristike, odnosno da je vjerodostojna te spremna i sposobna postupiti u obostranim interesima. Promatrajući ovaj konstrukt prema prethodno navedenim kategorijama, autori definiraju njegova četiri podkonstrukta:

1. Mišljenje o povjerenju – *kompetencija*, koji znači da osoba sa sigurnošću vjeruje kako je druga strana sposobna ili ima mogućnost učiniti ono što je potrebno. U kontekstu online trgovine, kupac vjeruje kako je trgovac sposoban adekvatno isporučiti dobra i usluge.
2. Mišljenje o povjerenju – *benevolencija*, koji predstavlja vjerovanje kako druga strana mari o pojedincu i motivirana je djelovati u njegovom interesu, odnosno procjena da je online trgovac benevolentan znači da pojedinac misli kako prvospomenuti nije sposoban za oportunističko djelovanje.
3. Mišljenje o povjerenju – *integritet* predstavlja snažno vjerovanje kako je druga strana iskrena te ispunjava obećanja, što u kontekstu online trgovine implicira vjerovanje kako će online trgovac djelovati u skladu s obećanim, odnosno isporučiti proizvod ili uslugu prema dogovoru te da će adekvatno raspolagati s osobnim podacima.
4. Mišljenje o povjerenju – *predvidljivost* znači da pojedinac vjeruje kako je djelovanje druge strane, bilo ono pozitivno ili negativno, dovoljno konzistentno da pruža mogućnost predviđanja narednih koraka. One osobe kod kojih je ovaj podkonstrukt izražen vjeruju kako mogu predvidjeti buduća ponašanja online trgovca. Specifičnost predvidljivosti, za

razliku od ostala tri, je u tome što je neutralna po pitanju valencije, nije ni pozitivna ni negativna, već samo predstavlja procjenu o mogućnosti predviđanja.

Ovaj model povjerenja uključuje i dva temeljna utjecajna čimbenika: institucionalno povjerenje te dispoziciju povjerenju (McKnight i Chervany, 2001; McKnight i sur., 2002). Prema autorima, institucionalno povjerenje se odnosi na vjerovanje o postojanju potrebnih strukturnih uvjeta koji povećavaju vjerojatnost postizanja uspješnih ishoda u aktivnostima kao što je online trgovina. Dvije su dimenzije institucionalnog povjerenja: situacijska normalnost, vjerovanje da je okruženje adekvatno uređeno; te strukturno uvjerenje odnosno postojanje struktura kao što su garancije, regulacije, pravna definiranost, obećanja te druge procedure koje osiguravaju uspješnost transakcije (McKnight i sur., 2002). Dispozicija povjerenju ili sklonost povjerenju je mjera u kojoj je pojedinac spreman na zavisnost o drugima u širokom spektru situacija (McKnight i sur., 2002). Autori definiraju dvije dimenzije sklonosti povjerenju: vjera u humanost i stav povjerljivosti, gdje prva dimenzija znači da pojedinac pretpostavlja kako su ljudi općenito pravedni, s dobrim namjerama i pouzdani, a druga je više kao osobna strategija, a znači da bez obzira što pojedinac misli o ljudima i njihovim karakteristikama, smatra kako je pozitivni ishod vjerojatniji ukoliko ih tretira kao da jesu pouzdani i pravedni. Prema McKnightu i sur. (2002) razlika između dvije dimenzije dispozicije povjerenju jest u tome što se vjera u humanost odnosi na atribute generalne većine, dok stav povjerljivosti predstavlja osobni pristup u izgradnji odnosa s drugima. Valja napomenuti kako osobe s visokom dispozicijom povjerenju nisu lakovjerne niti naivno ignoriraju negativne znakove, već jednostavno u razmatranju potencijalnog transakcijskog partnera prave manje negativnih atribucija (Geyskens i sur., 1996).

Predstavljeni se model temelji na teoriji razložne akcije, prema kojoj vjerovanja vode prema stavovima, na kojima se temelje namjere ponašanja, a nakon čega u konačnici dolazi i do samog ponašanja (Fishbein i Ajzen, 1975, citirani u McKnight i sur., 2002). U kontekstu izgradnje povjerenja autori navode kako vjerovanja/mišljenja o povjerenju vode do namjere povjerenja, a koje rezultiraju u ponašanjima temeljenim na povjerenju. Nadalje, sklonost povjerenju utječe na mišljenja o povjerenju jer determinira osobne interpretacije situacija i odnosa. Dispozicija povjerenju također ima direktni utjecaj na namjere povjerenja, iako u manjoj mjeri jer su potonje, kako McKnight i sur. (2002) navode pod velikim posredničkim utjecajem mišljenja o povjerenju. Razumno je zaključiti kako će dispozicija povjerenju biti najznačajnija u situacijama u kojima pojedinac nema znanja ni informacija o akterima u određenoj situaciji pa će na uključene

konstrukte, osim direktnog, imati i posrednički utjecaj. Analogno tomu, prema McKnight i sur. (2002), ukoliko pojedinac ima određeno iskustvo unutar određenog konteksta, kao što je na primjer online trgovina, ono će direktno utjecati na institucijsko povjerenje, uslijed čega će i efekti dispozicijskog povjerenja biti pod posredničkim utjecajem institucijskog povjerenja. Institucijskom povjerenje, navode autori, je pozitivno povezano s mišljenjem o povjerenju i namjerama povjerenja, konkretno kupac kojem je web okruženje poznato i ugodno, vjerojatno će imati pozitivna mišljenja o povjerenju u online trgovinu.

6.4. Odnos offline i online povjerenja u kontekstu e trgovine

Neki navode kako je elektronsko okruženje samo drukčiji kontekst za postojeća razmatranja povjerenja, dok prema drugima novo okruženje zahtijeva nove konceptualizacije postojećih teorija, tj. njihovu prilagodbu na radikalne promjene u tržištu (Mukherjee i Nath, 2007). Tako Shankar i sur (2002) u ovom kontekstu definiraju dvije vrste povjerenja: *offline povjerenje* – uključuje aktivnosti poduzeća koje nisu bazirane na internetu (npr. direktna prodaja, klasični oblici komunikacije – telefonski i osobno, uobičajeni tipovi transakcija – plaćanje gotovinom i slično); te *online povjerenje* – uključuje aktivnosti poduzeća putem interneta, naročito njegove web stranice. Dok je u offline okruženju objekt povjerenja uglavnom osoba ili neki drugi entitet, kao što je poduzeće (Shankar i sur., 2002), u online okruženju to je web stranica, Internet ili tehnologija (Bart i sur., 2014).

Mukherjee i Nath (2007) iz literature izdvajaju temeljne parametre prema kojima se razlikuju offline i online povjerenje:

1. Fizička udaljenost između kupca i prodavača, odsutnost prodajnih predstavnika i odvojenost između kupca i predmeta kupnja
2. Odsutnost istovremenog postojanja u vremenu i prostoru
3. Odsutnost karakteristika ljudskih mreža
4. Odsutnost direktne povratne informacije

Tako bi kupac u klasičnoj trgovini u istu ušao te mogao prvo vizualno usporediti ponudu, zatim proizvode dotaknuti, uzeti u ruku, u nekim slučajevima i isprobati neke njegove karakteristike prije donošenja konačne odluke o kupovini (Kim i sur., 2008). Prema autorima, navedeno trenutno umanjuje percipirani rizik te ojačava kupčevo pozitivno mišljenje o trgovini. Suprotno tomu, prilikom kupovine preko interneta kupac mora pružiti osobne informacije, uključujući i financijske (Kim i sur., 2008). Moguće je zaključiti kako online transakcija uključuje puno više od razmjene

novca za proizvod ili uslugu, u kom se smislu gotovo odriče jednog dijela privatnosti, obzirom da mora pružiti i adresu, broj telefona, datum rođenja i slično, a u zamjenu za neizvjestan ishod – ne može proizvod procijeniti na nijedan drugi način osim putem slikovnog ili video prikaza na web stranici prodavača te informacija o specifikacijama, ne može ni biti u potpunosti siguran da će proizvod biti poslan, iako je plaćen, može doći do oštećenja u transportu i slično. Stoga i ne čudi viši stupanj percipiranog rizika prilikom donošenja odluke o online kupovini, koji je najčešća barijera u donošenju pozitivne odluke (Kim i sur., 2008).

S druge strane, Bart i sur (2014) smatraju kako postoje sličnosti u kupčevoj interakciji s web stranicom, odnosno fizičkom trgovinom te navodi kako bi se web stranica zapravo mogla promatrati kao izlog trgovine. Na tom su tragu i Shankar i sur. (2002) prema kojima je web stranica zapravo analogna prodajnom predstavniku koji treba uspostaviti povjerenje kako bi došlo do transakcije. Također, online trgovina pruža i određene prednosti za kupca, prvenstveno u smislu većeg izbora i dostupnosti proizvoda, a posebno po pitanju informacija o proizvodima te usporedbi među supstitutima, smatraju Mukherjee i Nath, (2007). Autori nadalje navode kako upravo veća ponuda te konkurencija među ponuditeljima jednog proizvoda dovodi do suverenosti potrošača, a koja zajedno s fizičkom razdvojenosti prodavača i kupca te kupca i proizvoda rezultira činjenicom da je pitanje povjerenja zapravo centralni problem online trgovine. Bart i sur. (2014) smatraju kako online povjerenje uključuje kupčevu percepciju o tome kako će web stranica ispuniti očekivanja, koliko su ispravne informacije na stranici te koliko je zapravo vjerodostojna sama stranica.

Online trgovina svoje mjesto ima i u multikanalnom marketingu, upravo jer je kroz marketinške kanale konzistencija pristupa od centralnog značaja pa tako i po pitanju transfera online i offline povjerenja. Kao primjere Shankar i sur. (2002) navode web, telefon, e - mail, kiosk, poštu te klasičnu trgovinu gdje bi svaka dodirna točka (ili kanal) trebala imati određene zajedničke elemente uz svoje specifične karakteristike. Internet, osim transfera vrijednosti i unificirajućih elemenata ponude, pruža i mogućnost pristupa informacijama s višestrukih izvora, uključujući i one koji nisu pod kontrolom poduzeća. Tako u fokus dolazi interaktivni model komunikacije *mnogi – prema – mnogima (eng. many – to – many),* koji predstavlja srž značaja weba kao medija za razmjenu (Hoffman i Novak, 1996; citirani u Mukherjee i Nath, 2007). Navedeno znači da potencijalni kupac može komunicirati s prodavačima, drugim kupcima ili sa samim tehnološkim okruženjem, a osim toga kupci se uključuju i u kreiranje sadržaja o proizvodu i/ili poduzeću koji ostaje dostupan svim drugim potencijalnim kupcima (Mukherjee i Nath, 2007).

7. Istraživanje

7.1. Hipoteze istraživanja

Prethodno definirani predmet i problem istraživanja temelj su postavljenim hipotezama istraživanja:

H1: Postoji značajna razlika u korisničkim osvrtima obzirom na vrstu proizvoda/usluge

Kako je prethodno bilo govora, dobra se mogu podijeliti na tri kategorije – dobra s karakteristikom pretraživanja, iskustva i povjerenja. Mogućnost procjene proizvoda ili usluga prije kupovine ili konzumacije varira među navedenim kategorijama. Tako je proizvode s karakteristikom pretraživanja relativno jednostavno procijeniti prije same kupovine ili korištenja pa se očekuje kako će korisnički osvrti za ova dobra sadržavati pretežno objektivne naznake koje se odnose na njihova funkcionalna obilježja. Procjena iskustvenih dobara prema dostupnim informacijama je kompleksnija nego u slučaju prethodno spomenutih dobara, međutim nakon konzumacije potrošač je u stanju opisati iskustvo i razinu zadovoljstva proizašlu iz iste. Stoga se pretpostavlja kako će korisnički osvrti za dobra s karakteristikom iskustva sadržavati djelomično objektivne, a djelomično subjektivne naznake. Treću kategoriju dobara, onih s karakteristikom povjerenja je prosječnom potrošaču teško procijeniti čak i nakon korištenja jer mu često nedostaje znanje ili stručnost. Zbog toga, pretpostavlja se kako će korisnički osvrti za ova dobra biti pretežito subjektivni.

U skladu s navedenim, u sklopu ove hipoteze definiraju se tri podhipoteze:

H1a: Postoji značajna razlika u objektivnosti korisničkih osvrta za dobra s karakteristikom ***pretraživanja*** *i karakteristikom* ***iskustva***

H1b: Postoji značajna razlika u objektivnosti korisničkih osvrta za dobra s karakteristikom ***pretraživanja*** *i karakteristikom* ***povjerenja***

H1c: Postoji značajna razlika u objektivnosti korisničkih osvrta za dobra s karakteristikom ***iskustva*** *i karakteristikom* ***povjerenja***

H2: Korisnički osvrti s uključenim pozitivnim i negativnim komentarima rezultiraju značajno većim percipiranim povjerenjem od osvrta s isključivo pozitivnim ili negativnim komentarima

Hipoteza proizlazi iz prethodno razrađenih razloga zbog kojih pojedinci brže primjećuju negativne signale, tj. osvrte, međutim ukoliko osvrt uključuje isključivo negativne komentare,

postavit će se pitanje vjerodostojnosti, odnosno motivacije za pisanje takvog osvrta. Slično pitanje vjerodostojnosti i posljedično povjerenja vrijedi za isključivo pozitivne osvrte.

H3: Individualna sklonost povjerenju ima statistički značajan pozitivan utjecaj na percepciju vjerodostojnosti komunikacija u kontekstu e-trgovine

Obzirom da se pojedinci imaju različite karakteristike sklonosti povjerenju, razumno je pretpostaviti kako će spomenuta, kao značajan čimbenik uspostavljanja povjerenja u društvenim i drugim odnosima, značajno utjecati na percipirano povjerenje u online kupovini.

H4: Segmenti korisnika se razlikuju obzirom na sklonost povjerenju

Pretpostavlja se kako je temeljem individualnih karakteristika urođene sklonosti povjerenju moguće identificirati i izdvojiti različite segmente korisnika u kontekstu online trgovine.

7.2. Metodologija istraživanja

7.2.1. Rudarenje teksta i analiza sentimenta

Pod pojmom podataka dugo su se vremena podrazumijevale brojke i grafovi pa i danas kada su dostupne ogromne količine podataka, tzv. velikih podataka (eng. big data) (RapidMiner, 2018). Međutim, zahvaljujući sve sofisticiranijim analitičkim alatima te razvoju i primjeni novih multidisciplinarnih grana, kao što je na primjer strojno učenje, sve značajniji postaje i kvalitativni, tekstualni sadržaj. Moguće je pratiti i analizirati sadržaj korisničkih osvrta, objava na društvenim mrežama, blogova korisnika, što istraživačima nudi detaljan uvid u ponašanje potrošača, a poslovnim subjektima pruža korisne ulazne informacije za donošenje poslovnih odluka.

7.2.1.1. Prikupljanje podataka

Za potrebe rudarenja teksta potrebno je prikupiti podatke, konkretno korisničke osvrte. Kao izvor podataka odabrana je najveća američka platforma za e-trgovinu – Amazon.com. Tomu je tako iz više razloga, prvi je jezično ograničenje programskih rješenja za analizu teksta zbog čega je uputno izvoditi analizu na engleskom jeziku. Drugi razlog je što je dijapazon nuđenih proizvoda i usluga na Amazonu izuzetno širok pa je bilo moguće obuhvatiti korisničke osvrte na sve analizirane kategorije proizvoda s istog izvora. Tako se neutralizira eventualan utjecaj same platforme, tj. e-trgovine u smislu jednostavnosti i prepreka ostavljanju korisničkih recenzija. Konačno, sama popularnost i veličina Amazon.coma podrazumijeva mnoštvo aktivnih subjekata te posljedično i osvrta.

Korisnički su osvrti preuzeti korištenjem aplikacije ParseHub koja omogućava automatizaciju prikupljanja. Djeluje na način definiranja naredbi koji dio web stranice se prikuplja i u kojem obliku, određivanja klikova na dugme za sljedeću stranicu te koliko je stranica potrebno ”prelistati” (Slika 22). Kriterij za odabir proizvoda i usluga koji ulaze u analizu su razlika u prosječnim ocjenama, kako bi se obuhvatili pozitivni, neutralni i negativni komentari te broj osvrta. Primjeri dobara s **karakteristikom pretraživanja** su štednjaci, pametni telefoni i pametni satovi, dok su predstavnici dobara s **iskustvenom karakteristikom** knjige savjeta, filmovi i televizijske serije, a usluge kao što su stručna procjena doma, vodoinstalaterski i električni popravci primjeri dobara s **karakteristikom povjerenja**.

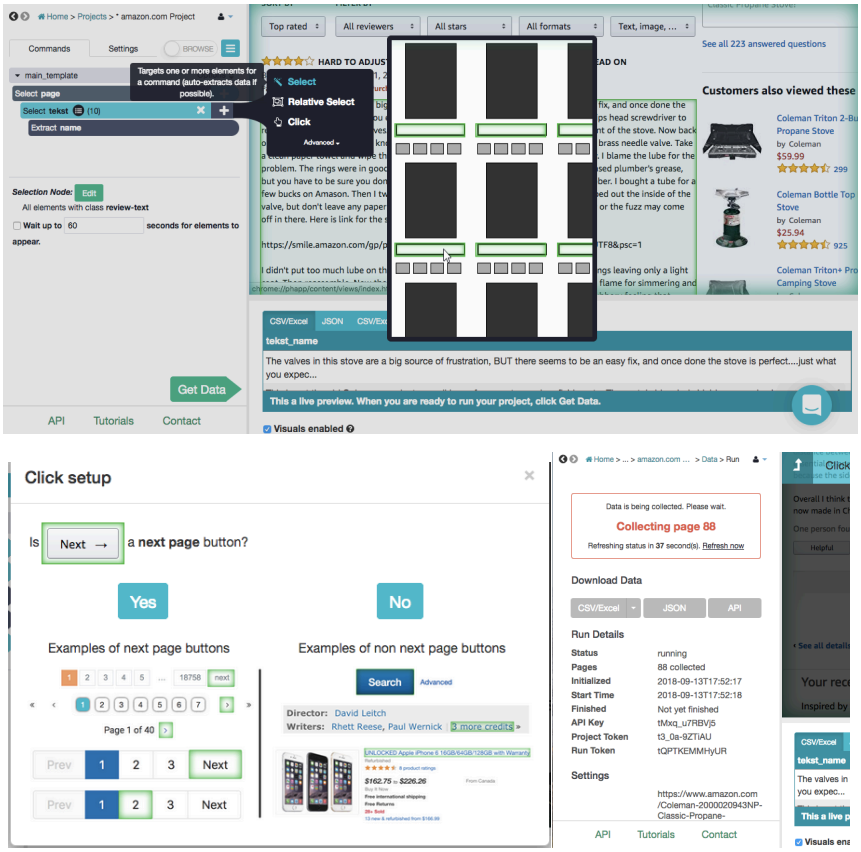

Slika 22. ParseHub određivanje narebi za prikupljanje korisničkih osvrta

Izvor: Istraživanje

Korisnički osvrti su za svaki odabrani proizvod sortirani u zasebne dokumente, koji su obrađeni na način da im je format prilagođen za analitičku obradu, uklonjen je višak podataka (oznake unutar dokumenata) te su adekvatno označeni.

7.2.2. Anketni upitnik

Anketni je upitnik strukturiran u tri segmenta. Prvi sadrži pitanja o osnovnim demografskim podacima, u drugom se segmentu ispituje utjecaja korisničkih osvrta na percepciju predstavljenog proizvoda, njihovu korisnost te sklonost prema kupnji proizvoda iz online trgovine korištene u upitniku, dok treći segment ispituje definirane elemente povjerenja.

Drugi je segment upitnika koncipiran u tri dijela, pri čemu je u svakom predstavljen isti proizvod s tri različita korisnička osvrta: potpuno pozitivni, potpuno negativni te osvrt s uključenim negativnim i pozitivnim karakteristikama proizvoda.

Prema istraživanju provedenom od strane portala eCommerce Hrvatska (2017), najbolji hrvatski web shop prema korisničkom iskustvu je Mobis.hr, koji je ostvario najviše ocjene prema stavkama početne stranice, navigacije, rasporeda kategorija i cijena, stranica s predstavljenim proizvodima, pretraživanje, mobilne verzije stranice i plaćanja. Stoga je s Mobis.hr preuzet proizvod kojim se ispituje utjecaj korisničkih osvrta, u nastojanju da se isključi utjecaj povjerenja temeljenog na karakteristikama i funkcionalnošću stranice za e-trgovinu, tj. institucionalnog povjerenja. MasterIndex istraživanje o navikama korištenja financijskih usluga za 2017. godinu (Netokracija, 2017) pokazalo je kako se u Hrvatskoj online najviše kupuju obuća, odjeća i modni dodaci, a zatim elektronička oprema. Predmetni proizvod u anketnom upitniku je pametni sat, odabran kao predstavnik elektroničke opreme te u izvjesnoj mjeri i modnih dodataka. Opravdanje takvog odabira leži u pokušaju isključivanja utjecaja osobnog modnog ukusa, spola i dobi prilikom odgovora. Također, u prikazu proizvoda su isključene oznake branda i cijene, zbog sklonosti određenim brandovima te različite individualne spremnosti na financijske izdatke. U svakom se od tri dijela drugog segmenta ispituje percipirana vjerodostojnost autora te samog osvrta pitanjima: *"Autor komentara je bio iskren", "Korisnički osvrt realistično opisuje iskustvo korištenja ovim proizvodom"* i *"Kada bi mi trebao pametni sat, ovaj bi mi osvrt bio koristan"*. Također, ispituje se spremnost kupovine predmetnog proizvoda iz predstavljene online trgovine pitanjima *"Kada bi mi trebao pametni sat, ovu stranicu bih uzeo/la u obzir za kupnju"* i *"Kada bi mi trebao pametni sat, razmotrio/la bih ovaj model"*. Ispitanicima su ponuđeni odgovori u rasponu od *"Uopće se ne slažem"* do *"Potpuno se slažem"* sa šest stupnjeva u cilju izbjegavanja utjecaja sklonosti ispitanika prema odabiru neutralne vrijednosti odgovora.

Treći segment za cilj ima ispitivanje elemenata povjerenja koji proizlaze iz osobnih sklonosti, a relevantni su za online kupovinu. Prvi ispitivani konstrukt povjerenja je benevolentnost

koju autori (Mayer i sur. 1995; Geyskens i sur. 1996; McKnight i Chervany, 2001; McKnight i sur. 2002) predstavljaju kao vjerovanje kako osobe u odnosu mare o drugima te su motivirane djelovati u interesu drugih. Tvrdnje korištene za ispitivanje benevolentnosti su *"Uglavnom, ljudima je stalo do dobrobiti drugih", "Tipična osoba vodi računa o problemima drugih ljudi"*, *"U većini slučajeva, ljudima je stalo do drugih i žele biti od pomoći"* te *"Uglavnom, ljudi vode računa samo o sebi"*.

Integritet je moguće definirati kao vjerovanje da su ljudi u pravilu iskreni, drže do svojih obećanja te da su spremni djelovati u cilju ispunjenja svoje riječi (Mayer i sur. 1995; Williamson i sur. 1975; Mukherjee i Nath, 2007; McKnight i Chervany, 2001; McKnight i sur. 2002). Ispitivan je putem tvrdnji *"U većini slučajeva ljudi ispune svoja obećanja", "Mislim da ljudi uglavnom nastoje djelima potkrijepiti svoju riječ"* te *"Većina ljudi je iskrena u interakciji s drugima"*. Posljednji ispitivani konstrukt povjerenja je stav povjerljivosti koji predstavlja osobnu strategiju uspostavljanja odnosa s drugima, kroz vjerovanje kako je pozitivni ishod odnosa vjerojatniji ukoliko se ljude tretira kao da jesu pouzdani i pravedni (McKnight i Chervany, 2001; McKnight i sur. 2002). Stav povjerljivosti testiran je tvrdnjama *"U većini slučajeva vjerujem ljudima dok mi ne daju razlog za suprotno", "Uglavnom ne donosim sud o ljudima temeljem prvog dojma"* te *"Moj pristup ljudima je da im vjerujem sve dok mi svojim djelima ne pokažu da im se ne treba vjerovati"*. Korištene tvrdnje su preuzete i prilagođene hrvatskom jeziku od McKnight i sur. (2002), a kao i u drugom segmentu anketnog upitnika, ponuđeni su odgovori u rasponu od *"Uopće se ne slažem"* do *"Potpuno se slažem",* u vidu ljestvice sa šest stupnjeva kako bi se izbjegao utjecaj sklonosti ispitanika prema odabiru neutralne vrijednosti odgovora.

7.2.2.1. Prikupljanje podataka

Podaci su prikupljeni korištenjem online alata Google Docs u periodu od kraja kolovoza do druge polovice rujna 2018. godine. Prednosti spomenutog alata su višestruke. S jedne strane omogućava izradu anketnog upitnika s uključenim vizualnim elementima, što je za potrebe ovog istraživanja bilo neophodno. Moguće je i razdvajanje upitnika na cjeline kako bi se osigurala preglednost te kako ispitanici ne mogu vidjeti naredne dijelove upitnika koji bi mogli utjecati na njihove odgovore. Također, svi su odgovori označeni kao neophodni zbog čega nije moguće prijeći u narednu cjelinu čime se osigurava cjelovito ispunjavanje upitnika. Nadalje, jednostavnost distribucije upitnika online kanalima je također prednost, zbog čega je u relativno kratkom roku

bilo moguće prikupiti potreban broj ispitanika. Dodatno, rezultate upitnika je moguće preuzeti u Excel formatu jednostavnom za daljnju pripremu i obradu podataka u SPSS statističkom programskom rješenju. Nedostaci su u nemogućnosti kontrole ispitanika, tj. iskrenosti njihovih odgovora te mogućnosti da isti ispitanik anketni upitnik ispuni više od jednom.

7.2.2.2. Uzorak istraživanja

U istraživanju je bilo nemoguće formirati slučajni uzorak zbog nedostatka podataka o cjelokupnoj istraživanoj populaciji. Tako se u ovom istraživanju koristi namjerni – prigodni uzorak, obzirom da nije moguće utvrditi broj jedinica u populaciji (Tkalac Verčić i sur., 2010). Tomu je tako zbog dostupnosti ispitanika, kao i potrebe dostizanja odgovarajuće veličine uzorka kako bi se udovoljilo zahtjevima analize ovog istraživanja. Kvote prema dobi i/ili spolu nisu rađene jer pregledom literature i dostupnih istraživanja nije utvrđeno da je isto potrebno.

Uzorak se sastoji od ukupno 137 ispitanika, od čega je njih 81, tj. 59,1% ženskog spola, a 56, tj. 40,9% muškog (Tablica 2).

Tablica 2. Spolna struktura uzorka

Spol	*Broj*	*Postotak (%)*
Ž	81	59,1
M	56	40,9
Ukupno	137	100

Izvor: Istraživanje

U dobnoj strukturi uzorka (Tablica 3) prevladavaju ispitanici u dobi od 22 do 25 godina, s 46%, a slijede ih ispitanici dobi od 26 do 29 godina s 26,3% te dobi između 18 i 21 godine s 16,1%. U manjoj su mjeri zastupljene skupine ispitanika između 30 i 33 godine, 34 i 37 godina te onih preko 38 godina sa udjelima od 5,1%, 3,6% i 2,9%.

Tablica 3. Dobna struktura uzorka

Dob	*Broj*	*Postotak (%)*
18-21	22	16,1
22-25	63	46
26-29	36	26,3
30-33	7	5,1
34-37	5	3,6
38+	4	2,9
Ukupno	137	100

Izvor: Istraživanje

7.3. Analiza sentimenta

Analiza sentimenta ili analiza polarnosti koristi se za identifikaciju pozitivnih i negativnih izražaja u tekstu (Hu i sur., 2012). Temelji se na tehnikama strojnog učenja, procesiranja prirodnog jezika te pristupa *bag-of-words,* kojim se izrazi predstavljaju u jednostavnom obliku prilagođenom za analizu. Ne tako davno, za provođenje analize sentimenta potrebno je bilo koristiti dva seta podataka – set za učenje, koji je uglavnom bio lista riječi s pripadajućim osjećajima te testni set, onaj koji se analizirao. Danas je pak dostupno više rješenja koja se sve više oslanjaju na tehniku strojnog učenja.

7.3.1. Provođenje analize sentimenta

U svrhu provođenja analize korišten je program RapidMiner, verzija 9.0.00.1. Analiza u spomenutom programu provodi se definiranjem koraka u procesu te u izvjesnim slučajevima dodatnih radnji u potprocesima, odnosno određivanjem naredbi vizualno predstavljenih operatorima. Svaki od njih ima dodatne mogućnosti kalibriranja parametara prema potrebama korisnika, tj. konkretne analize. Prvi je korak unošenje dokumenata u RapidMiner odabirom operatora *Read documents* te odabirom odgovarajućeg dokumenta. Po sedam je dokumenata prikupljeno i uneseno za proizvode s karakteristikom pretraživanja i iskustva te pet za proizvode s karakteristikom povjerenja. Potonjih je manje jer se na Amazonu nude u manjoj mjeri te je za njih dostupno manje korisničkih osvrta.

Tekst unutar dokumenata je u obliku rečenica s veznicima, interpunkcijskim znakovima, brojevima i sličnim, a što nije primjereno za daljnju analizu. Stoga se uvodi operator *Process documents*, prikazano na donjoj slici.

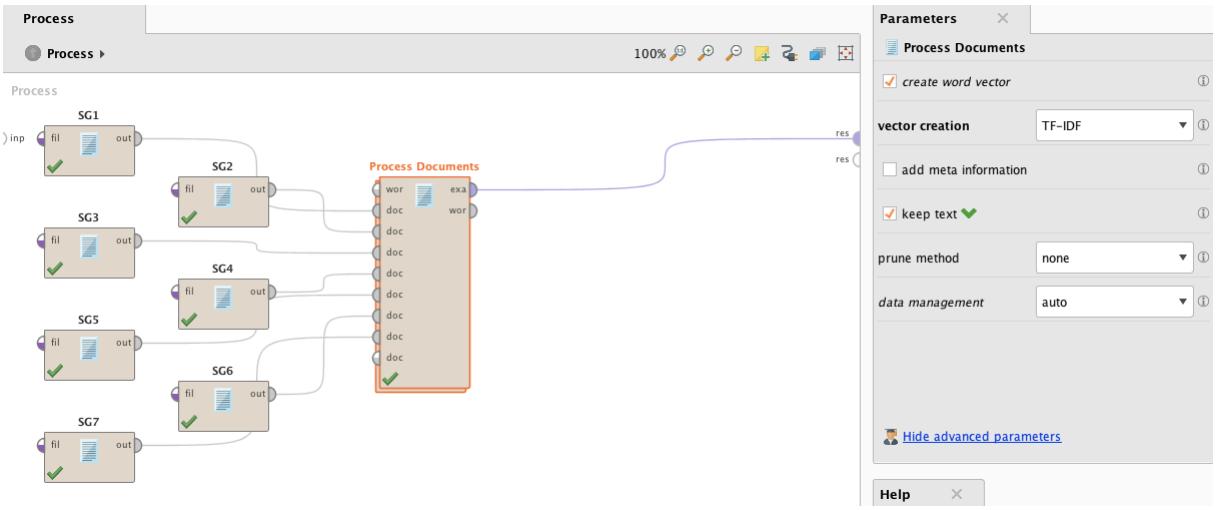

Slika 23. Učitavanje dokumenata u RapidMiner i definiranje glavnog procesa

Izvor: Istraživanje

Operator je kalibriran za formiranje vektora riječi korištenjem TF-IDF metode, tj. učestalost pojmova – inverzija učestalosti u dokumentu (eng. term frequency–inverse document frequency). Putem spomenute metode operator određuje koliko je neka riječ ili pojam značajna u dokumentu ili u setu dokumenata. Vrijednost TF-IDF raste proporcionalno s brojem puta pojavljivanja riječi u dokumentu, a smanjuje se s učestalosti pojavljivanja riječi u cijelom setu analiziranih dokumenata, čime se neutralizira činjenica da se neke riječi koriste češće (RapidMiner, 2018). U sklopu ovog operatora definira se podproces obrade teksta (Slika 24). Potproces započinje odabirom operatora *Transform cases* koji cijeli tekst prebacuje u oblik pisanja malim tiskanim slovima. Zatim se operatorom *Tokenize* tekst razlaže na riječi, pri čemu je moguće odabrati više kriterija prema kojima se navedena akcija provodi, a u ovom su slučaju odabrani svi znakovi koji nisu slova – prazna mjesta i interpunkcijski znakovi. Nadalje se filtriraju veznici i slične jezične čestice preko operatora *Filter stopwords* te *Filter tokens*. Nakon razlaganja cjeline teksta na riječi i filtriranja čestica, slijedi svođenje riječi na njihov korijen, uvođenjem operatora *Stem (Porter)*. Ovaj operator putem Porterovog algoritma u iteracijama uklanja sufikse sve dok se riječ ne svede na minimalnu duljinu. Rezultat je svođenje više oblika jedne riječi na jedinstveni oblik, a što za cilj ima smanjivanje ukupnog broja atributa te bržu i jednostavniju analizu. Konačno, operatorom *Generate n-Grams* se određuju fraze, odnosno riječi koje se najčešće pojavljuju zajedno.

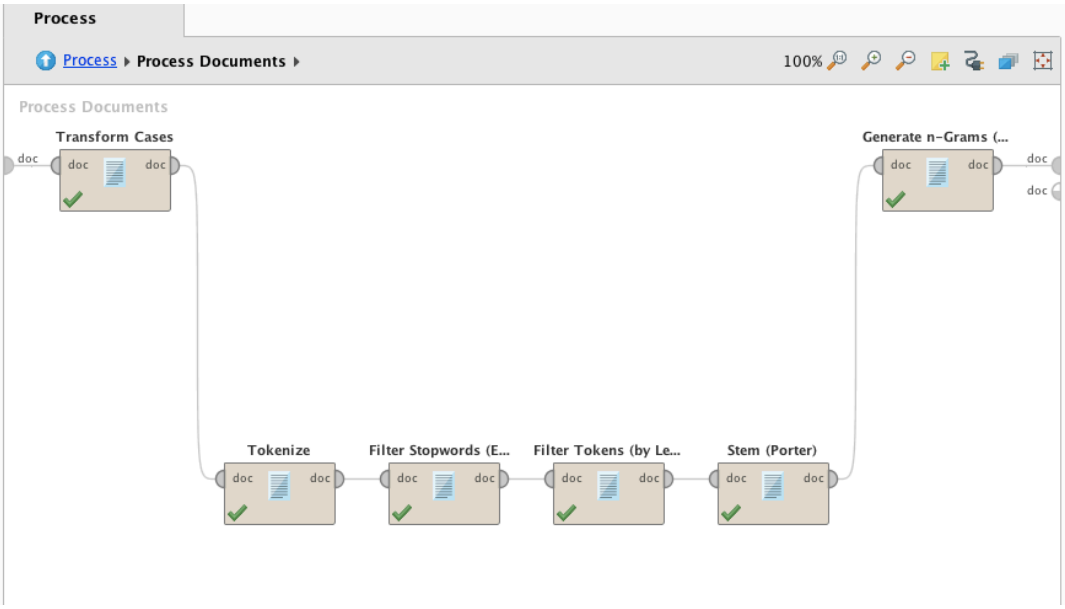

Slika 24. Definiranje podprocesa unutar operatora Process Documents

Izvor: Istraživanje

Ovim je postupkom set podataka za dobra s karakteristikom pretraživanja dao 56 054 atributa (riječi i fraza), za dobra s karakteristikom iskustva 114 316, a za dobra s karakteristikom povjerenja 116 472. Sljedeći korak je u povratak u glavni proces te uvođenje operatora *Analyze sentiment,* koji predstavlja nadogradnju Rapidminera od treće strane, poduzeća Aylien specijaliziranog za analitička rješenja koja uključuju strojno učenje i umjetnu inteligenciju. *Analyze sentiment* operator, odnosno akcije u sklopu njega temelje se na principima strojnog učenja, a kreiranjem korisničkog profila moguće je spojiti se na Aylien bazu pomoću koje se analiza izvršava. Nakon kalibracije operatora, tj. određivanja atributa, baze na koju se spaja te oblika sentimenta, počinje se s analizom.

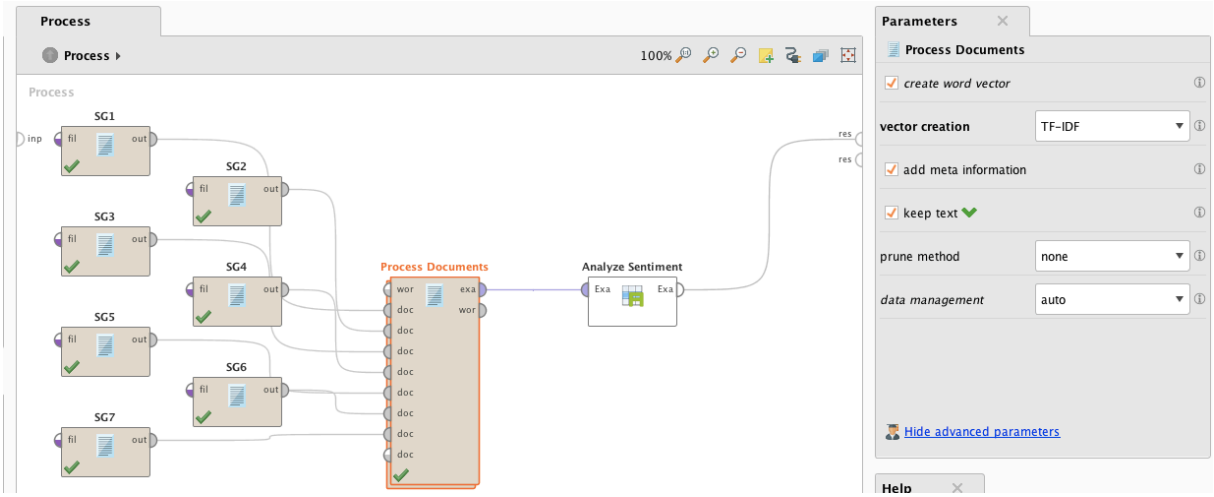

Slika 25. Uvođenje operatora Analyze Sentiment

Izvor: Istraživanje

7.3.2. Rezultati analize sentimenta

Prethodno opisani postupak je proveden za sve tri kategorije dobara. Rezultati analize sentimenta za dobra s karakteristikom pretraživanja su pokazala kako je pet skupina osvrta pozitivnog sentimenta te po jedna negativnog i neutralnog sentimenta. Pouzdanost procjene polarnosti, tj. sentimenta se uglavnom kreće u visokim vrijednostima – od 99% za prvi set, 84%, 80,1%, 76,2%, 67,8% za sedmi, drugi, četvrti i peti set, dok su vrijednosti pouzdanosti za treći i šesti set u nešto nižim vrijednostima od 49% i 58,1%. Što se pouzdanosti procjene subjektivnosti tiče, ona je za sve setove podataka na razini od 100%. Ono što iznenađuje jesu rezultati procjene subjektivnosti. Prema analizi sentimenta, četiri su seta podataka subjektivnog karaktera, a tri objektivnog, što je suprotno pretpostavci. Naime, obzirom da se radi o dobrima s karakteristikom pretraživanja, čija su obilježja lako procjenjiva, pretpostavljalo se kako će većina osvrta biti objektivnog karaktera. Drugim riječima, pretpostavka je bila kako će se u korisničkim osvrtima uglavnom koristiti atributi povezani s obilježjima proizvoda, a u manjoj mjeri osobni stavovi, međutim rezultati ne potvrđuju navedeno (Tablica 4).

Tablica 4. Rezultati analize sentimenta za dobra s karakteristikom pretraživanja

REDNI BR. DOKUMENTA	POLARNOST	POUZDANOST PROCJENE POLARNOSTI	SUBJEKTIVNOST	POUZDANOST PROCJENE SUBJEKTIVNOSTI
1	Pozitivna	0,999	Subjektivno	1
2	Pozitivna	0,801	Objektivno	1
3	Pozitivna	0,490	Objektivno	1
4	Pozitivna	0,762	Subjektivno	1
5	Negativna	0,678	Subjektivno	1
6	Neutralna	0,581	Subjektivno	1
7	Pozitivna	0,840	Objektivno	1

Izvor: Istraživanje

Rezultati analize sentimenta za dobra s karakteristikom iskustva sukladni su s pretpostavkom kako su korisnički osvrti za ovu kategoriju dobara dijelom objektivni, a dijelom subjektivni. Četiri su seta dokumenata s korisničkim osvrtima pretežito subjektivna (prvi, treći, peti i sedmi), a tri dominantno objektivna (drugi, četvrti i šesti). Pouzdanost procjene subjektivnosti je 100% za sve setove dokumenata. Prema polarnosti su čak tri seta neutralnog sentimenta, tri pozitivna, a samo jedan negativan. Pouzdanost procjene sentimenta je u tri slučaja iznad 90% i to 98,3%, 98% i 92,8% za šesti, peti i drugi set osvrta. Visoka je vrijednost pouzdanosti i za prvi set koji je na razini od 80,5% i sedmi na razini od 69,3%, dok su četvrti i treći set osvrta na nešto nižim razinama od 52,5% i 43,7%.

Tablica 5. Rezultati analize sentimenta za dobra s iskustvenom karakteristikom

REDNI BR. DOKUMENTA	POLARNOST	POUZDANOST PROCJENE POLARNOSTI	SUBJEKTIVNOST	POUZDANOST PROCJENE SUBJEKTIVNOSTI
1	Neutralna	0,805	Subjektivno	1
2	Pozitivna	0,928	Objektivno	1
3	Negativna	0,437	Subjektivno	1
4	Neutralna	0,525	Objektivno	1
5	Pozitivna	0,980	Subjektivno	1
6	Pozitivna	0,983	Objektivno	1
7	Neutralna	0,693	Subjektivno	1

Izvor: Istraživanje

Treća analizirana skupina korisničkih osvrta je ona koja se odnosi na dobra s karakteristikom povjerenja. Iz rezultata je vidljivo kako su prema polarnosti sve skupine osvrta subjektivnog izražaja, što je u skladu s očekivanim. Pouzdanost procjene subjektivnosti je i u ovom slučaju za sve skupine na razini od 100%. Prva su dva seta dokumenata pozitivnog sentimenta s

razinama pouzdanosti procjene polarnosti od 42,2% i 95,8%, četvrti i peti su pretežito negativnog sentimenta, s pouzdanosti od 92,9% i 44,7%. Treći je set osvrta pak neutralan, uz pouzdanost o 57,3%.

Tablica 6. Rezultati analize sentimenta za proizvode s karakteristikom povjerenja

REDNI BR. DOKUMENTA	POLARNOST	POUZDANOST PROCJENE POLARNOSTI	SUBJEKTIVNOST	POUZDANOST PROCJENE SUBJEKTIVNOSTI
1	Pozitivna	0,422	Subjektivno	1
2	Pozitivna	0,958	Subjektivno	1
3	Neutralna	0,573	Subjektivno	1
4	Negativna	0,929	Subjektivno	1
5	Negativna	0,447	Subjektivno	1

Izvor: Istraživanje

Dodatna mogućnost koju analiza sentimenta pruža jest uvid u sentimente sadržane u pojedinim frazama. Graf pod rednim brojem 1 prikazuje odnos sentimenata za frazu *item_custom* te je vidljivo kako ima niske vrijednosti za negativne i pozitivne sentimente, a visok za neutralne. Fraza *simple_plug* (2) ima nisku vrijednost za pozitivne sentimente te se kreće od neutralnog ka negativnom sentimentu, gdje dostiže svoj vrhunac. Iz navedenog se može izvući zaključak kako su korisnici jednostavnost utičnice predmetnog proizvoda pretežito ocijenili kao nedostatak. *Figure_complex* (3) rangira nisko za neutralne i pozitivne sentimente te srednje vrijednosti za negativni kontekst.

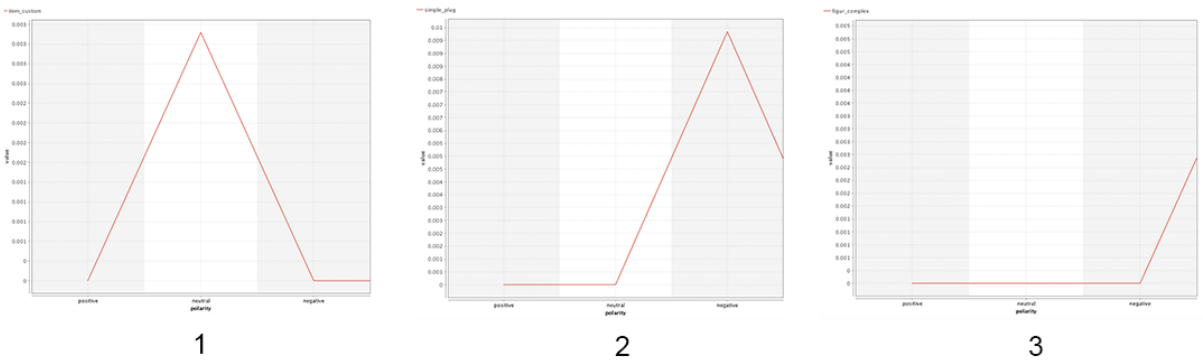

Slika 26. Odnos sentimenata za fraze item_custom (1), simple_plug (2) i figure_complex (3)

Izvor: Istraživanje

Sentimenti riječi *outweigh* (4) se bilježe rast od neutralnih do negativnih vrijednosti, a *feel_batteri* (5) visoko je rangirana u pozitivnim kontekstima, srednje visoko u negativnim, dok nema neutralnog konteksta. Zanimljiv je slučaj potonje fraze, jer sugerira kako korisnici nikad nisu

neutralni oko trajanja baterije, već uvijek imaju izražen pozitivni ili negativni sentiment. Za konkretni proizvod to je bio pretežito pozitivan osjećaj, dok je u dijelu osvrta ova fraza bila spomenuta u negativnom kontekstu. Jednako je zanimljiva i fraza *skilled_and* (6) koja se uopće ne spominje u negativnom kontekstu, a graf polarnosti bilježi rast od pozitivnog ka neutralnom sentimentu.

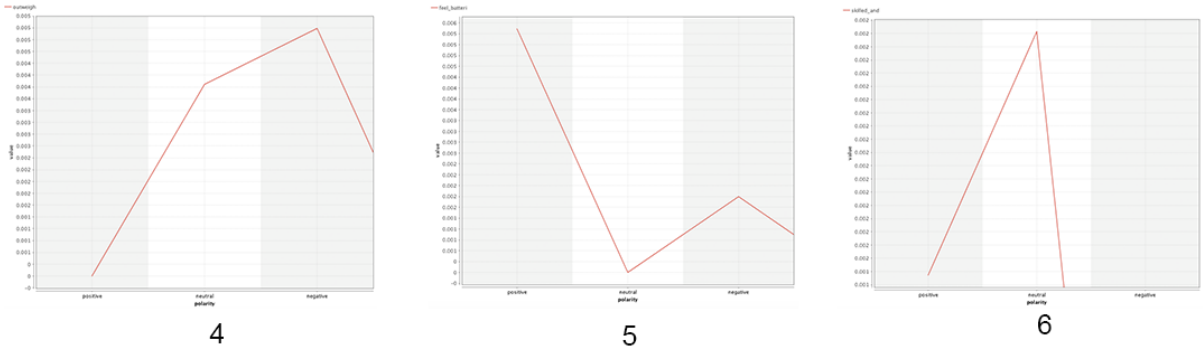

Slika 27. Odnos sentimenata za fraze outweigh (4), feel_batteri (5) i skilled_and (6)

Izvor: Istraživanje

Good_experi (7) i *great_deal* (8) su fraze koje upućuju na pozitivno iskustvo pa stoga i ne čudi što obje bilježe visoke vrijednosti pozitivnog sentimenta. Ipak, *good_experi* ima visoko izražen i neutralni sentiment, dok je *great_deal* na srednjoj razini. Obje fraze imaju nisko izražen negativni sentiment. Posljednja prikazana fraza, *professional_from* (9) je prema sentimentu pretežito pozitivna, s nisko izraženim neutralnim i negativnim sentimentima, a što se odnosi na profesionalnost osoblja s kojim su korisnici bili u kontaktu.

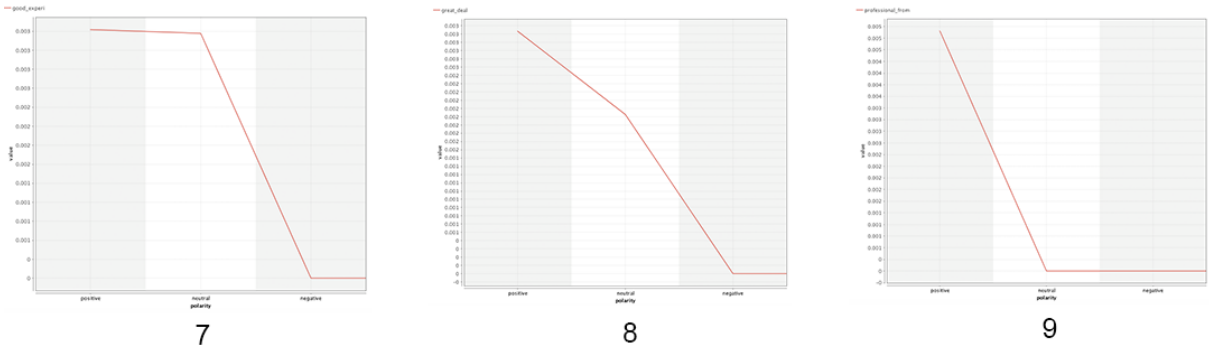

Slika 28. Odnos sentimenata za good_experi (7), great_deal (8) i professional_from (9)

Izvor: Istraživanje

7.4. Friedmanova ANOVA

U svrhu ispitivanja razlike u percipiranom povjerenju u vjerodostojnost autora i korisničkog osvrta obzirom na pripadajući sentiment provedena je Friedmanova analiza varijance. Navedena se analiza provodi za testiranje razlike u više zavisnih skupova ili drugim riječima, kada se različita eksperimentalna stanja testiraju na istom uzorku (Field, 2006). Riječ je o neparametrijskoj analitičkoj metodi koja je primjerena jer su odgovori u rasponu od 1 – potpuno nepovjerenje do 6 – potpuno povjerenje. Također, primjerenost odabira Friedmanove ANOVA-e se ogleda i u činjenici da se u konkretnom istraživanju ispitivanje percipiranog povjerenja na tri različita osvrta provelo na istim ispitanicima. Dakle, skupine odgovora vezanih uz percipiranu vjerodostojnost za različite kategorije korisničkih osvrta se tretiraju kao zavisni skupovi.

Kako je prethodno bilo govora, percipirana se vjerodostojnost testirala izjavama *"Autor komentara je bio iskren", "Korisnički osvrt realistično opisuje iskustvo korištenja ovim proizvodom"* i *"Kada bi mi trebao pametni sat, ovaj bi mi osvrt bio koristan"* za svaki osvrt. Od spomenutih su čestica upitnika formirani indeksi koji predstavljaju jedinstvenu ocjenu percipirane vjerodostojnosti za svaku kategoriju korisničkog osvrta. Njihovom međusobnom usporedbom, ali i usporedbom odgovora pojedinih izjava za sve kategorije korisničkih osvrta se dobio uvid u razlike percipirane vjerodostojnosti.

7.4.1. Friedmanova ANOVA za indekse percipirane vjerodostojnosti

Prije same analize varijance provodi se testiranje normalnosti distribucije odgovora korištenjem Kolmogorov-Smirnov i Shapiro-Wilk testa. Kako su za oba testa vrijednosti signifikantnosti ispod 5% moguće je zaključiti kako distribucije triju indeksa nisu u parametrima normalne distribucije te je stoga moguće nastaviti s neparametrijskom Friedmanovom ANOVA-om (Tablica 7).

Tablica 7. Test normalnosti distribucije indeksa percipirane vjerodostojnosti

Test normalnosti distribucije

	Kolmogorov-Smirnov test			Shapiro-Wilk test		
	Rezultat	Stupnjevi slobode	Signifikantost	Rezultat	Stupnjevi slobode	Signifikantost
PercVjerodost_Poz	0,183	137	0,000	0,912	137	0,000
PercVjerodost_Mix	0.200	137	0,000	0,910	137	0,000
PercVjerodost_Neg	0,112	137	0,000	0,961	137	0,001

Izvor: Istraživanje

U donjoj su tablici prikazani rezultati Friedmanove ANOVA-e za ispitivanje razlike među indeksima percipirane vjerodostojnosti prema različitom sadržaju korisničkog osvrta. Analiza srednjih vrijednosti pokazala je kako indeks percipirane vjerodostojnosti za korisničke osvrte s pozitivnim i negativnim sadržajem ima veću srednju vrijednost od indeksa s isključivo pozitivnim i isključivo negativnim sadržajem. Tako je srednja vrijednost indeksa *PercVjerodost_Mix* 5,029, odnosno odgovori su prosječno u rasponu *Slažem se* s navedenom tvrdnjom. *PercVjerodost_Poz* ima vrijednost 4,307 što znači da je prosječni odgovor *Djelomično se slažem*, a vrijednost *PercVjerodost_Neg* je 3,469 što upućuje na prosječni odgovor *Djelomično se ne slažem*. Vrijednosti rangova Friedmanove ANOVA-e potvrđuju rezultate analize srednjih vrijednosti te *PercVjerodost_Mix* ima najviši rang od 2,68. Signifikantnost analiza varijance je $p < 0,000$, tj. na razini je manjoj od 5% te je moguće zaključiti kako korisnički osvrti s uključenim pozitivnim i negativnim komentarima rezultiraju značajno većim indeksom percipiranog povjerenja od osvrta s isključivo pozitivnim ili negativnim komentarima.

Tablica 8. Test razlike srednjih vrijednosti rangova za indekse percipirane vjerodostojnosti

Friedmanov test

	Srednji rang	Srednja vrijednost
PercVjerodost_Poz	1.91	4.307
PercVjerodost_Mix	2.68	5,029
PercVjerodost_Neg	1.41	3,469
N	137	/
Asimp. signif.	0,000	/
Egzaktna signif.	0,000	/

7.4.2. Friedmanova ANOVA za pojedine tvrdnje percipirane vjerodostojnosti autora i osvrta

7.4.2.1. Percipirana iskrenost autora osvrta

Prije provođenja Friedmanove ANOVA-e provedeni su Kolmogorov-Smirnov i Shapiro-Wilk testovi s ciljem testiranja normalnosti distribucije odgovora. Kao i u prethodnom slučaju signifikantnost normalnosti distribucije je ispod 5%. Navedeno sugerira kako odgovori na tvrdnje *Autor komentara je bio iskren_POZ, Autor komentara je bio iskren_MIX* te *Autor komentara je bio iskren_NEG* nisu normalno distribuirani, odnosno u odgovorima postoji sistematičnost te je moguće provesti Friedmanovu ANOVA-u.

Tablica 9. Test normalnosti distribucije percipirane iskrenosti autora

Test normalnosti distribucije

	Kolmogorov-Smirnov testa[a]			Shapiro-Wilk test		
	Rezultat	Stupnjevi slobode	Signifikantost	Rezultat	Stupnjevi slobode	Signifikantost
Autor komentara je bio iskren_POZ	0,269	137	0,000	0,841	137	0,000
Autor komentara je bio iskren_MIX	0.259	137	0,000	0,799	137	0,000
Autor komentara je bio iskren_NEG	0,168	137	0,000	0,925	137	0,000

Izvor: Istraživanje

Rezultati analize srednjih vrijednosti sugeriraju kako je percipirana iskrenost autora osvrta najviša za korisničke osvrte s uključenim pozitivnim i negativnim sadržajem te je na razini od 5,161. Navedena srednja vrijednost sugerira kako su odgovori prosječno u rasponu *Slažem se* s navedenom tvrdnjom. *Autor komentara je bio iskren_POZ* te *Autor komentara je bio iskren_NEG* imaju niže srednje vrijednosti koje su na razinama od 4,336 za prvu te 3,861 za potonju tvrdnju. Moguće je stoga zaključiti kako su se odgovori u prvom slučaju prosječno kretali u rasponu *Djelomično se slažem,* a u drugom *Djelomično se ne slažem.* Friedmanova ANOVA je dala srednje rangove koji su analogni srednjim vrijednostima odgovora na tvrdnje, te je vidljivo korisnički osvrti s uključenim pozitivnim i negativnim sentimentom rezultira ima najviši rang percipirane iskrenosti autora, koji je na razini od 2,51. Prema navedenom kriteriju slijedi korisnički osvrt s potpuno pozitivnim sentimentom čiji je rang 1,86. Najniži rang - 1,63 imaju korisnički osvrti s potpuno negativnim sentimentom. Obzirom da je signifikantnost analize varijance $p < 0,000$, dakle na razini manjoj od 5%, proizlazi zaključak kako zaključiti kako korisnički osvrti s uključenim pozitivnim i

negativnim komentarima rezultiraju značajno većom percepcijom iskrenosti autora od osvrta s isključivo pozitivnim ili negativnim komentarima

Tablica 10. Test razlike srednjih vrijednosti rangova percipirane iskrenosti autora osvrta

Friedmanov test

	Srednji rang	Srednja vrijednost
Autor komentara je bio iskren_POZ	1.86	4.336
Autor komentara je bio iskren_MIX	2.51	5,161
Autor komentara je bio iskren_NEG	1.63	3,861
N	137	/
Asimp. signif.	0,000	/
Egzaktna signif.	0,000	/

Izvor: Istraživanje

7.4.2.2. Percipirana vjerodostojnost osvrta

Rezultati Kolmogorov-Smirnov i Shapiro-Wilk testova sugeriraju kako je moguće nastaviti s Friedmanovom ANOVA-om, obzirom da distribucije odgovora na dotične tvrdnje nisu slučajne. Drugim riječima, ne udovoljavaju parametrima normalne distribucije, što potvrđuju razine signifikantnosti od p<0,000, tj. p<5%.

Tablica 11. Test normalnosti distribucije percipirane vjerodostojnosti osvrta

Test normalnosti distribucije

	Kolmogorov-Smirnov testa[a]			Shapiro-Wilk test		
	Rezultat	Stupnjevi slobode	Signifikantost	Rezultat	Stupnjevi slobode	Signifikantost
Vjerodostojnost osvrta_POZ	0,283	137	0,000	0,827	137	0,000
Vjerodostojnost osvrta _MIX	0.299	137	0,000	0,811	137	0,000
Vjerodostojnost osvrta _NEG	0,164	137	0,000	0,921	137	0,000

Izvor: Istraživanje

Vjerodostojnost osvrta testirana je tvrdnjom *"Korisnički osvrt realistično opisuje iskustvo korištenja ovim proizvodom"* te srednje vrijednosti sugeriraju kako ispitanici najvjerodostojnijim smatraju korisnički osvrt s pozitivnim i negativnim komentarima. Njegova je srednja vrijednost 5,063 te ima i najviši rang od 2,58. Razina signifikantnosti p<5% potvrđuje da je moguće zaključiti kako **korisnički osvrti s uključenim pozitivnim i negativnim komentarima rezultiraju značajno većom percipiranom vjerodostojnošću od osvrta s isključivo pozitivnim ili negativnim komentarima.**

Tablica 12. Test razlike srednjih vrijednosti rangova percipirane vjerodostojnosti osvrta

Friedmanov test

	Srednji rang	Srednja vrijednost
Vjerodostojnost osvrta_POZ	2	4.38
Vjerodostojnost osvrta_MIX	2.58	5,036
Vjerodostojnost osvrta_NEG	1.42	3,445
N	137	/
Asimp. signif.	0,000	/
Egzaktna signif.	0,000	/

Izvor: Istraživanje

7.4.2.3. Percipirana korisnost osvrta

Kolmogorov-Smirnov i Shapiro-Wilk testovi normalnosti upućuju kako odgovori na tvrdnju o korisnosti osvrta nisu distribuirani prema parametrima normalne distribucije, uz razinu signifikantnosti manjoj od 5%. Stoga je moguće nastaviti s Friedmanovom ANOVA-om.

Tablica 13. Test normalnosti distribucije percipirane korisnosti osvrta

Test normalnosti distribucije

	Kolmogorov-Smirnov testa[a]			Shapiro-Wilk test		
	Rezultat	Stupnjevi slobode	Signifikantost	Rezultat	Stupnjevi slobode	Signifikantost
Korisnost osvrta_POZ	0,241	137	0,000	0,880	137	0,000
Korisnost osvrta _MIX	0.272	137	0,000	0,849	137	0,000
Korisnost osvrta _NEG	0,173	137	0,000	0,896	137	0,000

Izvor: Istraživanje

Srednje vrijednosti za percipiranu korisnost osvrta, testirane tvrdnjom *"Kada bi mi trebao pametni sat, ovaj bi mi osvrt bio koristan",* pokazuju kako ispitanici najkorisnijim smatraju onaj korisnički osvrt koji uključuje i pozitivan i negativan sadržaj. Najmanje korisnim pak smatraju onaj korisnički osvrt s potpuno negativnim komentarima, dok osvrt s potpuno pozitivnim sadržajem ima srednju vrijednost od 4,204. Rezultati srednjih rangova Friedmanove ANOVA-e su u skladu s analizom srednjim vrijednost te se uz pouzdanost od $p<5\%$ može zaključiti kako korisnički osvrti s uključenim pozitivnim i negativnim komentarima rezultiraju značajno većom percipiranom korisnošću od osvrta s isključivo pozitivnim ili negativnim komentarima.

Tablica 14. Test razlike srednjih vrijednosti rangova percipirane korisnosti osvrta

Friedmanov test

	Srednji rang	Srednja vrijednost
Korisnost osvrta_POZ	2,03	4.204
Korisnost osvrta_MIX	2.5	4,891
Korisnost osvrta_NEG	1.47	3,102
N	137	/
Asimp. signif.	0,000	/
Egzaktna signif.	0,000	/

Izvor: Istraživanje

7.5. Faktorska analiza

Faktorska analiza je statistička metoda identificiranja skupina varijabli s ciljem reduciranja broja varijabli, a u isto vrijeme zadržavajući što je više moguće originalnih informacija (Field, 2006). U ovom su istraživanju analizirane komponente povjerenja od značaja za online trgovinu, konkretno za prvo susretanje s istom i to benevolentnost, integritet i stav o povjerenju. Svaka od njih testirana s nekolicinom tvrdnji/čestica tako da je ukupno deset ulaznih varijabli, koje su prethodno navedene. Dakle, faktorskom se analizom nastojalo smanjiti broj ukupnih varijabli kroz definiranje faktorskog opterećenja pojedinačnih u skupnim varijablama – faktorima. U tom smislu faktorsko opterećenje predstavlja relativnu važnost pojedine čestice za sam faktor.

Kao metoda faktorske analize odabrana je analiza glavnih komponenti (eng. principal components analysis) koja olakšava tumačenje strukture matrice varijanci i kovarijanci ulaznih varijabli kroz njihove linearne kombinacije. Obzirom na testirane sastavnice povjerenja moguće je pretpostaviti krajnji broj faktora, međutim provela se eksplorativna faktorska analiza. Razlog tomu je nastojanje što preciznijeg definiranja faktora, tj. njihovih pripadajućih čestica, bez njihova prisilnog smještanja u faktore. Kao kriterij ulaska koristio se Kaiserov kriterij prema kojem samo čestice s vrijednošću eigenvalue 1 ili više mogu postati dijelom faktora. Nadalje, korištena je varimax rotacija koja osigurava da su opterećenja varijabli maksimizirana za jedan faktor, a minimizirana za ostale faktore, odnosno nastoji maksimizirati disperziju opterećenja varijabli

unutar faktora. Na ovaj se način postiže minimalni broj relevantnih varijabli u sklopu svakog faktora što olakšava daljnju interpretaciju.

U analizu je prvo uvedeno svih deset varijabli te su uz odabranu metodu faktorske analize, varimax rotacije te kriterij minimalnog opterećenja od 0,5 izolirana četiri faktora. Svi su faktori udovoljavali Kaiserovom kriteriju (eigenvalue > 1) te je njima objašnjeno 80,095% ukupne varijance u uzorku. Ipak, primjetne su problematične čestice i to 5.4. koja nije imala odgovarajuće opterećenje za nijedan faktor te 5.5. koja je imala unakrsno opterećenje za faktore 2 i 3 (Tablica 15).

Tablica 15. Preliminarna rotirana faktorska matrica

Komponenta	*Faktori*			
	1	2	3	4
5.1.	0,796			
5.2	0,814			
5.3.	0,836			
5.4.				
5.5.		0,551	0,647	
5.6.		0,936		
5.7.		0,787		
5.8.				
5.9.			0,919	
5.10.				0,828

Izvor: Istraživanje

Potom su problematične varijable uklonjene te je analiza ponovljena uz minimalno opterećenje povećano na razinu 0,6. Ovog su puta dobivena tri faktora koja zajedno objašnjavaju 72,483% ukupnih varijacija u uzorku (Tablica 17). Također, sva tri faktora udovoljavaju Kaiserovom kriteriju, tj. imaju eigenvalue veći od jedan što je vizualno prikazano scree testom (Slika 29). Valja napomenuti da se kao jedan od kriterija odabira broja faktora uzima točka

prijeloma grafa scree testa, međutim kako je vidljivo na slici, u ovom je slučaju najizraženija točka prijeloma nakon prvog faktora. Kako navedeno nije prihvatljivo, odabran je Kaiserov kriterij.

Tablica 16. Kaiserov kriterij

Varijabla	*Eigenvalue*	*% objašnjenih varijacija*	*Kumul. % obj. Varijacija*
1	***3,5***	28,451	28,451
2	***1,28***	23,383	51,835
3	***1,019***	20,648	***72,483***
4	0,826		
5	0,548		
6	0,324		
7	0,274		
8	0,228		

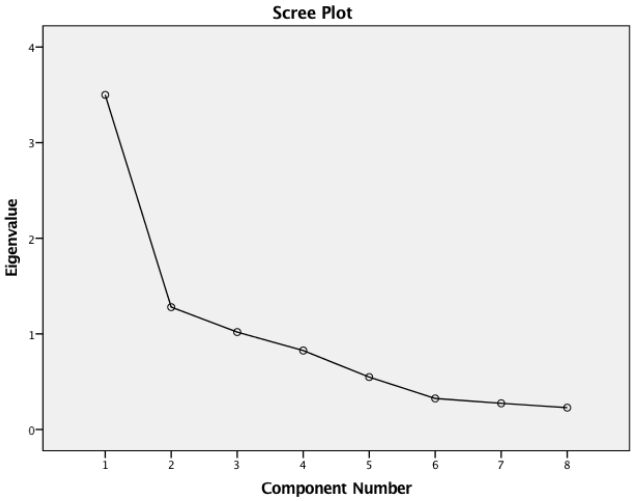

Slika 29. Scree test

Kaiser-Meyer-Olkinova mjera adekvatnosti uzorkovanja je 0,719 što spada u interval dobre adekvatnosti. Bartlettov test sferičnosti se pokazao statistički značajan s razinom signifikantnosti od $p < 0,00\%$. Iz navedenih se parametara može zaključiti kako je provedena faktorska analiza prikladna te se može nastaviti s daljnjom interpretacijom rezultata.

Tablica 17. Rotirana faktorska matrica - faktori uvršteni u analizu

Rotirana faktorska matrica

Varijable	**Faktori**		
	1	2	3
5.1.	,797		
5.2.	,830		
5.3.	,843		
5.6.		,871	
5.7.		,814	
5.8.			,790
5.9.			,704
5.10.			,624

Izvor: Istraživanje

Faktor 1 čine tvrdnje *Uglavnom, ljudima je stalo do dobrobiti drugih*, *Tipična osoba vodi računa o problemima drugih ljudi* te *U većini slučajeva, ljudima je stalo do drugih i žele biti od pomoći*. Svim je navedenim tvrdnjama testirana komponenta povjerenja **benevolentnost** te je shodno tomu ovaj faktor tako i nazvan.

Faktor 2 je nazvan **integritet** jer obuhvaća dvije od tri tvrdnje anketnog upitnika koje su se na ovu komponentu povjerenja i odnosile. Spomenute tvrdnje su *Mislim da ljudi uglavnom nastoje djelima potkrijepiti svoju riječ* i *Većina ljudi je iskrena u interakciji s drugima*.

Faktor 3 je nazvan **stav povjerljivosti** jer se sastoji od tvrdnji kojima je isti testiran, a one su *Uglavnom ne donosim sud o ljudima temeljem prvog dojma* i *Moj pristup ljudima je da im vjerujem sve dok mi djelima ne pokažu suprotno.*

7.6. Regresijska analiza

Utjecaj individualne sklonosti povjerenja na percepciju vjerodostojnosti komunikacija u kontekstu e-trgovine je testiran regresijskom analizom. Regresijska analiza se kao statistička metoda koristi u svrhu utvrđivanja utjecaja jedne ili više nezavisnih varijabli na zavisnu varijablu (Field, 2006). Drugim riječima, moguće je utvrditi funkcionalni odnos među varijablama, a temeljem toga formirati model kojim se mogu predvidjeti vrijednosti zavisne varijable za zadane vrijednosti nezavisne(ih) varijabli. U ovoj analizi zavisna varijabla je percepcija vjerodostojnosti komunikacije u kontekstu e-trgovine, a koja je predstavljena indeksom formiranim od čestica koje se odnose na percipiranu vjerodostojnost osvrta. Kao nezavisne varijable, tj. prediktori uvode se prethodno definirani faktori komponenti individualnog povjerenja: benevolentnost, integritet i stav povjerljivosti.

Prije provođenja regresijske analize korisno je utvrditi postojanje međusobne povezanosti varijabli, u koju se svrhu provodi korelacijska analiza. Ovaj korak nije neophodan, ali daje uvid u to koje varijable potencijalno ulaze u model kao regresori te indicira smjer njihova utjecaja. Iz korelacijske tablice je vidljivo kako postoji statistički značajna korelacija između percipirane vjerodostojnosti osvrta te dviju komponenti individualnog povjerenja: benevolentnosti i stava povjerljivosti. U oba je slučaja riječ o slaboj pozitivnoj korelaciji, na razini pouzdanosti manjoj od 5%.

Tablica 18. Korelacijska matrica

Analiza korelacije

		Indeks	Benevolentnost	Integritet	Stav povjerljivosti
Indeks	Korelacija	1	**0.307**	0.123	**0.212**
	Signifikantnost		**0.000**	0.151	**0.013**
Benevolentnost	Korelacija	0.307	1	0.000	0.000
	Signifikantnost	0.000		1	1
Integritet	Korelacija	0.123	0.000	1	0.000
	Signifikantnost	0.151	1		1
Stav povjerljivosti	Korelacija	0.212	0.000	0.000	1
	Signifikantnost	0.013	1	1	

Izvor: Istraživanje

Nakon što je utvrđena slaba pozitivna statistički značajna veza percipirane vjerodostojnosti osvrta s benevolentnosti i stava povjerljivosti provela se regresijska analiza. Valja napomenuti kako su se zbog naravi istraživanja u prvom koraku analize u regresiju uključile sve tri komponente individualne sklonosti povjerenju. Kao metoda odabira regresorskih varijabli odabrana je Stepwise metoda koja odabir varijabli provodi u iteracijama. Prva varijabla koja ulazi u model jest ona koja ima najviši stupanj korelacije sa zavisnom varijablom, a potom naredne varijable ulaze prema vrijednosti koeficijenta parcijalne korelacije sa zavisnom varijablom, uz razinu statističke signifikantnosti $p<5\%$. Pri tome se nezavisne varijable koje su već odabrane u model testiraju za izlazak iz modela, uz razinu signifikantnosti $p>10\%$.

Kako je bilo i moguće pretpostaviti obzirom na korelacijsku analizu, Stepwise metodom u regresijski su model ušle dvije nezavisne varijable s kojima je percipirana vjerodostojnosti osvrta bila u pozitivnom međuodnosu. Koeficijent determinacije modela R^2 pokazuje kako je ovim regresijskim modelom objašnjeno 13,9% zbroja kvadrata odstupanja u uzorku.

Tablica 19. Procjena regresijskog modela

Procjena modela

	R	R^2	Std. Greška	Durbin-Watson
Model	0.373	0.139	0.71007	2.074

Izvor: Istraživanje

Analizom varijance modela dobiveni su podaci o tumačenju modela, vidljivo u Tablici 20. Primjetno je kako reziduali tumače višestruko više odstupanja zavisne varijable od njene aritmetičke sredine, a razlog tomu može biti u potrebi uključivanja dodatnih varijabli koje nisu obuhvaćene ovim istraživanjem. Ipak, moguće je zaključiti kako je model u cjelini statistički značajan temeljem vrijednosti signifikantnosti F-testa koji je na razini p ≈ 0,000%.

Tablica 20. Analiza varijance regresijskog modela

ANOVA

	Suma kvadrata	df	Sredina kvadrata	F	Sig.
Regresija	10.922	2	5.461	10.831	0.000
Rezidual	67.563	134	0.504		
Total	78.485	136			

Izvor: Istraživanje

U donjoj je tablici dan pregled vrijednosti regresijskih parametara za nezavisne varijable benevolentnosti i stava povjerljivosti s njihovim procjenama statističke značajnosti. Obzirom da je t-test za konstantu i oba regresorska parametra statistički značajan uz signifikantnosti p ≈ 0,000%.

Tablica 21. Parametri regresijskog modela

Model		*Koeficijenti*	*St.greška*	*t*	*Sig.*
Regresijski model	Konstanta	4.287	0.061	70.668	0.000
	Benevolentnost	0.233	0.061	3.831	0.000
	Stav povjerljivosti	0.161	0.061	2.643	0.000

Izvor: Istraživanje

Dakle, regresijski model ima oblik:

$Y = 4.287 + 0{,}233 x X_1 + 0{,}161 x X_2$

Gdje je:

Y = percipirana vjerodostojnost osvrta

β_1 = benevolentnost

β_2 = stav povjerljivosti

Dobiveni model nema interpretativnu vrijednost u klasičnom smislu, obzirom na prirodu varijabli kojima je nemoguće utvrditi jediničnu vrijednost. Stoga nije moguće ni egzaktno utvrditi kretanje zavisne varijable prema vrijednostima nezavisnih. Ipak, model pruža uvid u smjer i intenzitet utjecaja benevolentnosti i stava povjerljivosti, kao komponenti individualne sklonosti povjerenju na percepciju vjerodostojnosti osvrta. Prema tome, moguće je zaključiti kako osobe s višim stupnjem benevolentnosti, tj. one koje vjeruju kako su drugi iskreni, vjerni svojoj riječi te spremni ispuniti svoja obećanja, imaju sklonost pozitivno vrednovati vjerodostojnost pročitanih korisničkih osvrta, uz isključen utjecaj stava povjerljivosti. Analogno tomu, osobe s višim stupnjem stava povjerljivosti, koje vjeruju ljudima dok im ne daju razlog za suprotno, bilo svojim djelima ili riječima te koje pružaju drugima priliku prije nego donesu sud o njima, također imaju sklonost pozitivno vrednovati vjerodostojnost pročitanih korisničkih osvrta, uz isključen utjecaj benevolentnosti.

7.6.1. Dijagnostika modela

Iako su model i pripadajući koeficijenti statistički značajni, prije donošenja krajnje ocjene reprezentativnosti modela potrebno testirati model na multikolinearnost, autokorelaciju te heteroskedastičnost. Navedeni parametri mogu narušiti prediktivnu i interpretativnu vrijednost modela te je stoga važno utvrditi njihovo (ne)postojanje.

Multikolinearnost se javlja u višestrukim regresijama gdje se među nezavisnim varijablama uočavaju sistematični odnosi. Indikatori multikolinearnosti su faktor inflacije varijance (VIF) te postotak tolerancije (TOL). Ukoliko je vrijednost VIF<5 i TOL>20% tada se utvrđuje kako u modelu nema problema multikolinearnosti. Prema podacima iz tablice moguće je vidjeti kako je VIF = 1, odnosno manji je od 5, dok je TOL na razini većoj od 20%. Stoga se zaključuje kako u ovom modelu nije prisutna multikolinearnost.

Tablica 22. Procjena multikolinearnosti

	TOL	*VIF*
Benevolentnost	1.000	1.000
Stav povjerljivosti	1.000	1.000

Izvor: Istraživanje

Autokorelacija reziduala znači da su slučajne greške, tj. reziduali u modelu međusobno korelirani, a što može uzrokovati greške u procjeni parametara i značajnosti istih te modela u cjelini. Kao indikator postojanja autokorelacije uvriježeno se uzima vrijednost Durbin-Watsonovog testa. Kriterij za utvrđivanje nepostojanja autokorelacije jest vrijednost testa jednaka ili blizu 2. Kako je vidljivo u tablici xx (di je R^2) vrijednost testa je 2,074 te se može zaključiti kako u ovom regresijskom modelu nije prisutna autokorelacija reziduala.

Ukoliko se regresijski model želi proglasiti reprezentativnim jedan od uvjeta je i homoskedastičnost reziduala, tj. nužnost da reziduali imaju normalnu distribuciju. U suprotnom, radi se heteroskedastičnosti. Navedeni problem znači da reziduali nisu slučajno distribuirani, već u njihovoj distribuciji postoji sistematičnost. Heteroskedastičnost se može procijeniti temeljem P-P grafa na kojem dijagonalna linija predstavlja teoretsku, normalnu distribuciju reziduala. U slučaju značajnih devijacija od teoretske linije donosi se zaključak postojanja heteroskedastičnosti. Na Slici 30. vidljivo je da stvarni reziduali ne odstupaju značajno od očekivane distribucije reziduala te je moguće zaključiti kako ne postoji problem heteroskedastičnosti.

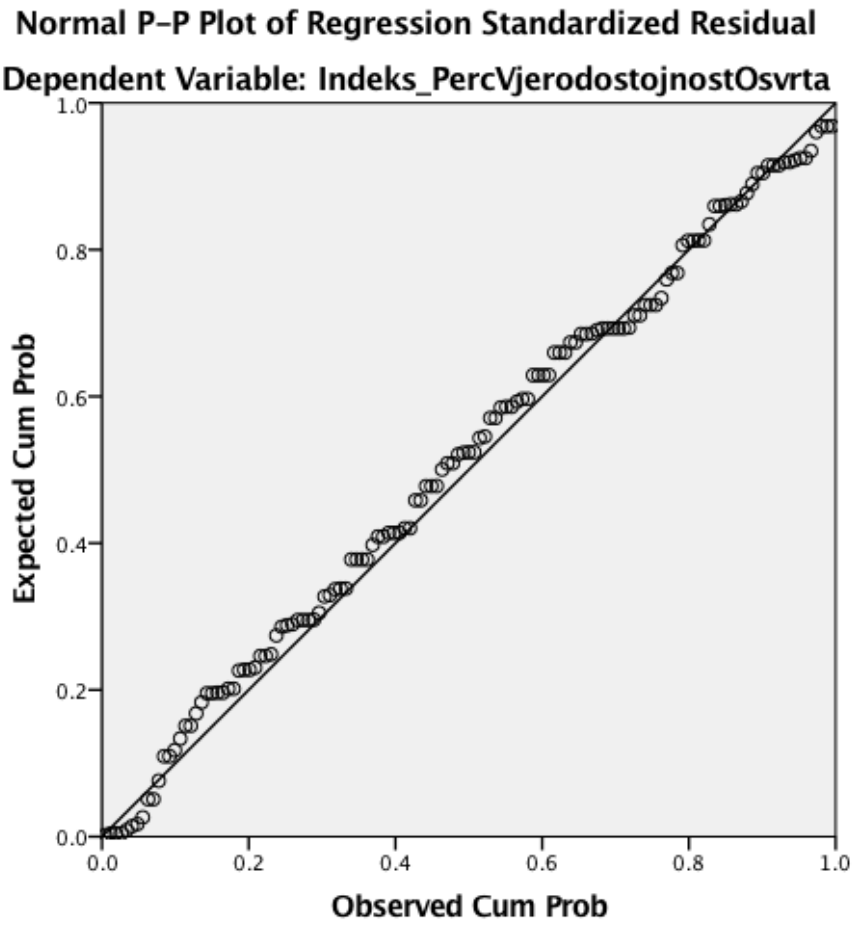

Slika 30. P - P graf standardiziranih reziduala

Izvor: Istraživanje

Potvrdu nepostojanja heteroskedastičnosti moguće je uočiti na dijagramu rasipanja gdje su predstavljeni odnosi standardnih reziduala regresije prema standardiziranim predviđenim vrijednostima. Ukoliko se zadovoljava uvjet homoskedastičnosti tada bi na grafičkom prikazu odnosa opaženih i predviđenih vrijednosti reziduala one trebale biti ravnomjerno raspršene, bez formiranja oblika (npr. oblik lijevka). Moguće je uočiti kako je to zaista i slučaj, uz nekolicinu potencijalno problematičnih reziduala koji značajno odstupaju od ostalih opažanja na dijagramu.

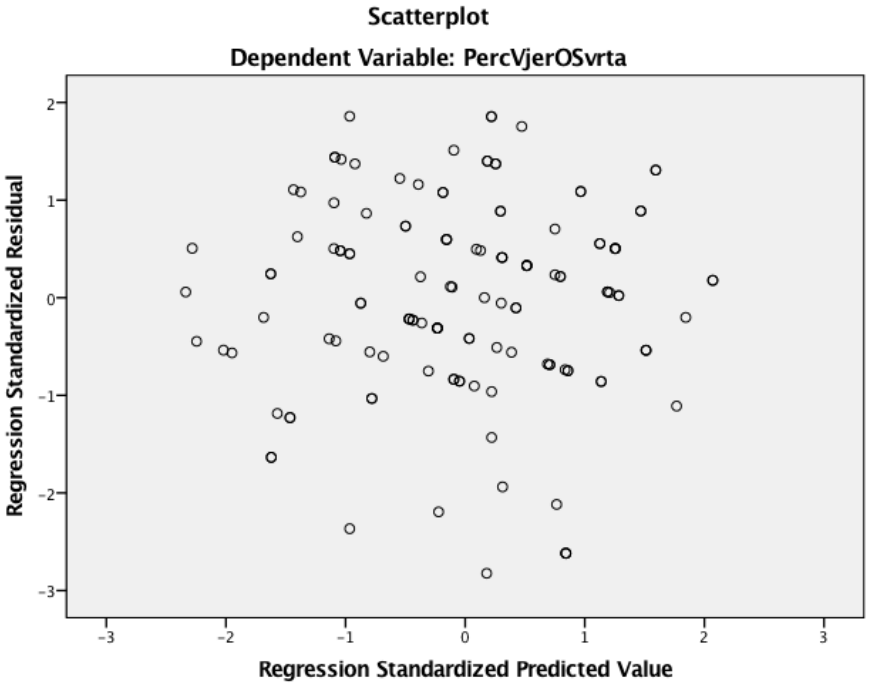

Slika 31. Dijagram rasipanja regresijom standardiziranih predviđenih vrijednosti i standardiziranih reziduala

Izvor: Istraživanje

Dodatno, moguće je provjeriti i heteroskedastičnost varijance reziduala putem Spearmonovog koeficijenta korelacije kojim se testira postojanje korelacije reziduala s regresorskim varijablama (Rozga, 2006). Rezultati korelacijske analize pokazuju kako između apsolutnih vrijednosti reziduala i regresorskih varijabli ne postoji statistički značajna korelacije. Prema tome, može se zaključiti kako u regresijskom modelu nije prisutna heteroskedastičnost varijance reziduala.

Tablica 23. Spearmanov koeficijent korelacije regresijskih varijabli i reziduala

Spearmanova korelacija

		Reziduali	Benevolentnost	Stav povjerljivosti
Reziduali	Korelacija	1.000	-0.032	0.001
	Sig.		**0.710**	**0.993**
Benevolentnost	Korelacija	-0.032	1.000	.054
	Sig.	**0.710**		**0.533**
Stav povjerljivosti	Korelacija	0.001	0.054	1.000
	Sig.	**0.993**	**0.533**	

Izvor: Istraživanje

7.7. Klaster analiza

Kako bi se identificirali segmenti korisnika prema urođenoj sklonosti povjerenju provodi se klaster analiza, a u sklopu nje metoda k-sredina. Urođena sklonost povjerenju predstavljena je prethodno identificiranim faktorima benevolentnosti, integriteta i stava povjerljivosti. Algoritam k-sredina određuje predstavnike skupina pridružujući svaku jedinku skupini s najbližim predstavnikom tako da zbroj kvadrata udaljenosti jedinki od predstavnika pripadajućih skupina bude minimalan, tj. kreira skupine s minimalnom ukupnom varijancom (Mirošević, 2016).

Odabir broja klastera ovisi o procjeni istraživača te su u nastojanju odabira adekvatnog broja provedena četiri eksplorativna testa. Cilj je usporediti klastere s dvije, tri, četiri i pet skupina te prema parametrima donijeti odluku o njihovom optimalnom broju. Konkretno, riječ je o statistčkoj značajnosti F-omjera, broja čestica u pojedinim klasterima te interpretativni smisao definiranih klastera. Pri tome valja napomenuti kako je preporuka da se F test koristi u deskriptivne svrhe, a ne kao primarni kriterij odluke. Naime, klasteri su odabrani kako bi se maksimizirala razlika među određenim klasterima. Tako je i u ovom slučaju temeljni kriterij da su vrijednosti F testa statistički značajne, a odluka se naknadno temelji na samim klasterima, u njihovom broju te opisnom smislu.

Vidljivo je dakle, kako opcija dva klastera nije reprezentativna jer vrijednost F-testa za benevolentnost nije statistički značajna. Za ostale je mogućnosti vrijednost dotičnog testa statistički značajna, što znači da će se daljnje odlučivanje voditi drugim parametrima.

Tablica 24. Analiza varijance različitih opcija odabira broja klastera

	F test							
	Broj klastera							
Faktori	2		3		4		5	
	F	sig.	F	sig.	F	sig.	F	sig.
Benevolentnost	0.000	.990	52.125	.000	57.228	.000	71.084	.000
Integritet	13.560	.000	9.774	.000	31.135	.000	23.198	.000
Stav povjerljivosti	192.069	.000	102.449	.000	52.390	.000	46.914	.000

Izvor: Istraživanje

U donjoj je tablici prikazan broj jedinki u mogućnosti odabira tri, četiri i pet klastera. Primjetno je kako u slučaju odabira pet klastera postoji disproporcija u broju jedinki. Najviše bi jedinki bilo u trećem klasteru, njih 47, a u drugom tek šest. Slično je i u odabiru četiri klastera, gdje

je u dva prisutan jednak broj, dok je u najbrojnijem 54, a u najmanjem devet. Najpovoljnija je situacija u slučaju odabira tri klastera, gdje dva imaju jednak broj jedinki (43), a u najbrojnijem je 51 jedinka. Usporedbom rasporeda jedinki uzorka u klasterima za različite mogućnosti, moguće je zaključiti kako se odabirom tri klastera postiže najravnomjernija raspodjela.

Tablica 25. Broj jedinki uzorka u klasterima za opcije odabira tri, četiri i pet klastera

Broj klastera	*Broj klastera*		
	3	**4**	**5**
1	43	37	38
2	51	37	6
3	43	9	47
4	/	54	22
5	/	/	24

Izvor: Istraživanje

Konačan odabir donesen je temeljem pregleda rasporeda komponenti povjerenja u sklopu identificiranih klastera. Kako je prethodno navedeno, narav analize je da prema definiranom broju grupira jedinke pri tome minimizirajući razlike unutar klastera, a maksimizirajući razlike između njih. Rezultat toga jest da u slučaju četiri i pet klastera postoji nekolicina s izraženom vrijednosti jednog od faktora, dok su druge dvije minimizirane. Tako bi se u interpretaciji moglo zaključiti kako su, na primjer, jedinke jedne skupine isključivo povjerljive prema drugima, dok istovremeno ne vjeruju u njihovu iskrenost i dobre namjere. Zaključci iz takve interpretacije ne bi imali smisla u pokušaju generalizacije na populaciju, jer kompleksnu ljudsku prirodu predstavljaju kao jednodimenzionalnu. Stoga su kao reprezentativna odabrana tri klastera, a srednje vrijednosti pojedine komponente u sklopu klastera su prikazane u donjoj tablici te vizualno na grafikonu.

Tablica 26. Srednje vrijednosti faktora prema segmentima

Srednje vrijednosti faktora prema klasterima

Faktor	*Klaster*		
	1	*2*	*3*
Benevolentnost	-0,6309	0,8454	-0,3718
Integritet	0,1513	-0,4466	0,3784
Stav povjerljivosti	0,8536	0,1822	-0,1070

Izvor: Istraživanje

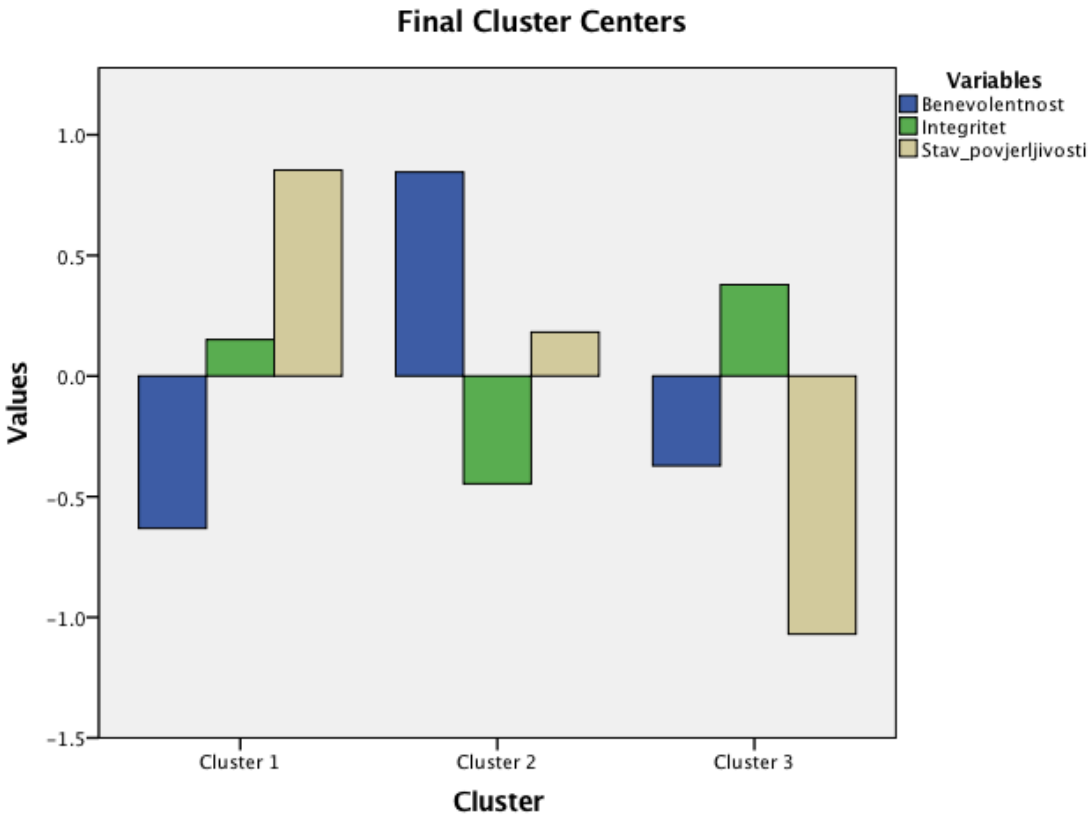

Slika 32. Grafički prikaz faktora prema segmentima

Izvor: Istraživanje

Dakle, klaster analizom moguće je identificirati tri segmenta prema komponentama individualne sklonosti povjerenju: benevolentnosti, integritetu i stavu povjerljivosti.

Segment 1 – jedinke koje imaju visoko pozitivno izražen stav povjerljivosti, odnosno koje ljudima pružaju priliku prije nego donesu sud o njima. Drugim riječima, smatraju kako se drugima treba vjerovati sve dok svojim djelima ne pokažu suprotno. Istovremeno, ocjena benevolentnosti je jako negativna. Iz toga proizlazi kako pripadnici ovog segmenta smatraju kako ljudi ne vode previše računa o problemima drugih te nemaju inicijativu pružiti pomoć. U ovom segmentu prevladavaju osobe ženskog spola, 74,4% te su pretežito u dobi od 22 do 25 godina (55,8%). Navedeno, zajedno s umjereno pozitivnim uvjerenjem kako drugi nastoje biti iskreni i djelima potkrijepiti svoju riječ vodi do zaključka kako jedinke ovog segmenta imaju povjerenja u druge pri čemu nemaju naivnih iluzija o općenitoj dobroćudnosti drugih. Stoga je ovaj segment nazvan *povjerljivi sa zadrškom*.

Segment 2 – u ovom segmentu su više zastupljene pripadnice ženskog spola, u udjelu od 58,8%, a 72,6% segmenta je u dobi od 22 do 29 godina. Kod jedinki ovog segmenta faktor

benevolentnosti je jako pozitivno izražen, dakle riječ je o osobama koji vjeruju da ljudi vode računa o drugima, njihovim problemima i dobrobiti. Međutim, ne vjeruju u integritet drugih u smislu da sumnjaju u njihovu iskrenost u pristupu i komunikaciji kao i u spremnost da izvrše svoja obećanja. Ipak, zamjetno je kako je faktor stava povjerljivosti kod ovog segmenta umjereno pozitivan, što indicira kako su spremni dati priliku prije formiranja slike o drugima. Dakle, riječ je o osobama koji usprkos svojoj vjeri u dobroćudnost drugih te spremnosti na pružanje prilike, sumnjaju u njihovu iskrenost i namjere. Prema navedenim karakteristikama pripadnika, segment je nazvan *dobroćudni skeptici*.

Segment 3 – jedini segment u kojem prevladava muški spol s 55,8%, pri čemu prevladavaju dobne skupine od 22 do 25 godina s 37,2% te 26 do 29 godina s 30,2%. Pripadnici ovog segmenta imaju jako negativno izražen faktor stava povjerljivosti, iz čega proizlazi da je njihov pristup ljudima takav da temeljem prvog dojma formiraju trajnu sliku o njima. Također, primjetna je i umjereno negativna vrijednost faktora benevolentnosti, što navodi na zaključak kako smatraju da drugi općenito stavljaju sebe i svoje potrebe na prvo mjesto, bez mnogo obzira prema drugima. Međutim, vjeruju da su ljudi u interakciji iskreni, što je moguće zaključiti iz umjereno pozitivne vrijednosti faktora integriteta. Riječ je o pojedincima koji ne smatraju potrebnim prvo upoznati osobu, već im je prvi dojam dovoljan za procjenu. Sudeći prema faktoru benevolentnosti pripadnici ovog segmenta smatraju kako su drugi uglavnom sebični te ne vode puno računa o tuđim brigama. S druge strane vjeruju kako ljudi uglavnom djelima opravdavaju svoju riječ te da su spremni ispuniti dana obećanja. Stoga je ovaj segment nazvan *integritet i predrasude.*

8. Rasprava rezultata analize

Analizom sentimenta na primjeru korisničkih osvrta za različite kategorije proizvoda testirale su se razlike u subjektivnosti, odnosno objektivnosti među istima. Rezultati su tek djelomično u skladu s pretpostavkama. Naime, bilo je govora kako se očekuje da će korisnički osvrti na proizvode s karakteristikom pretraživanja biti pretežito objektivni, na proizvode s iskustvenom karakteristikom djelomično objektivni, dok će proizvodi s karakteristikom povjerenja imati osvrte s pretežito subjektivnim obilježjima. Postavljena hipoteza pretpostavlja kako će se korisnički osvrti za spomenute kategorije međusobno razlikovati ovisno o obilježju subjektivnosti/objektivnosti. Međutim, analizom korisničkih osvrta utvrđeno je kako isti imaju jednak odnos subjektivnosti i objektivnosti za proizvode s karakteristikom pretraživanja te proizvode s iskustvenom karakteristikom, uz vrijednosti pouzdanosti procjene subjektivnosti od 100%. S druge strane, rezultati analize subjektivnosti korisničkih osvrta za kategorije proizvoda s karakteristikama iskustva i povjerenja daju očekivane rezultate. Kako je već spomenuto, setovi korisničkih osvrta za proizvode s iskustvenom karakteristikom imaju djelomično subjektivna obilježja, dok su u slučaju proizvoda s karakteristikom povjerenja svi setovi korisničkih osvrta subjektivni. U oba je slučaja vrijednost pouzdanosti procjene subjektivnosti na razini od 100%

Slijedom navedenog, *podhipoteza H1a* o značajnoj razlici u subjektivnosti korisničkih osvrta za proizvode s karakteristikom traženja te povjerenja *se odbacuje*. *Podhipoteze H1b* i *H1c se prihvaćaju* jer je prisutna značajna razlika u subjektivnosti između korisničkih osvrta za proizvode s karakteristikom povjerenja te onih s karakteristikom traženja i iskustva. Dakle, hipoteza H1 se djelomično prihvaća.

Druga hipoteza o statistički značajnom pozitivnom utjecaju korisničkih osvrta s uključenim pozitivnim i negativnim komentarima na percipiranu vjerodostojnost osvrta testirana je Friedmanovom ANOVA-om. U sklopu anketnog upitnika ispitanicima je prezentiran isti proizvod tri puta, ali s tri različita korisnička osvrta: potpuno pozitivni, potpuno negativni te osvrt s uključenim pozitivnim i negativnim komentarima. Za potrebe analize formirani su indeksi percipirane vjerodostojnosti uključivanjem odgovarajućih tvrdnji anketnog upitnika te je utvrđeno kako postoji statistički značajna razlika srednjih rangova među indeksima. Pri tomu, indeks percipirane vjerodostojnosti osvrta s pozitivnim i negativnim sentimentima je ostvario najviši srednji rang. Kao provjera, provedene su Friedman ANOVA analize i za pojedinačne tvrdnje anketnog upitnika koje su služile za formiranje indeksa. U sva tri slučaja je tvrdnja za osvrt s

uključenim pozitivnim i negativnim komentarima ostvarila najvišu vrijednost srednjeg ranga te je bila statistički značajna. Prema tome, moguće je zaključiti kako potencijalni kupci one korisničke osvrte u kojima su predstavljene pozitivne i negativne karakteristike proizvoda smatraju vjerodostojnijima od onih u kojima je fokus na isključivo pozitivnim ili negativnim karakteristikama. Iz navedenog slijedi kako se hipoteza H2 prihvaća.

Za potrebe testiranja treće i četvrte hipoteze provedena je faktorska analiza kako bi se temeljem uzorka definirale komponente individualne sklonosti povjerenju. Anketni upitnik je sadržavao ukupno deset tvrdnji koje su za cilj imale ispitati temeljne sastavnice spomenutog vida povjerenja, a one su: benevolentnost, integritet i stav povjerljivosti. Rezultat faktorske analize su faktori koji korespondiraju spomenutim sastavnicama individualne sklonosti povjerenju.

U trećoj se hipotezi pretpostavilo kako će individualna sklonost povjerenju statistički značajan pozitivan utjecaj na percepciju vjerodostojnosti komunikacija u kontekstu e-trgovine.
Kako bi se testirala hipoteza provedena je regresijska analiza s ciljem utvrđivanja smjera i intenziteta utjecaja nezavisnih varijabli na zavisnu. Potonja je u ovom slučaju percipirana vjerodostojnost osvrta, predstavljena indeksiranom vrijednošću tvrdnji koji se na istu odnose. Konačno, u finalnom su modelu dvije nezavisne varijable: benevolentnost i stav povjerljivosti. Integritet pak nije statistički značajno povezan sa zavisnom varijablom. Dijagnostika modela je pokazala kako nisu prisutni problemi multikolinearnosti, autokorelacije i heteroskedastičnosti. Međutim, model treba uzeti sa zadrškom, jer usprkos statističkoj značajnosti te odgovarajućim vrijednostima dijagnostičkih parametara, koeficijent determinacije pokazuje kako je objašnjeno svega 13,9% zbroja kvadrata odstupanja u uzorku. Razlog tomu je vjerojatno što na percipiranu vjerodostojnost osvrta utječu varijable koje ovim modelom nisu predviđene i obuhvaćene. Obzirom da se za reprezentativnost regresijskog modela uzima koeficijent determinacije od minimalno 70%, može se zaključiti kako ovaj regresijski model, iako statistički značajan, nije reprezentativan. Zajedno s činjenicom da model ne sadržava jednu od komponenti povjerenja, integritet, proizlazi zaključak kako se hipoteza H3 odbija.

Četvrtom je hipotezom pretpostavljeno kako je moguće identificirati i definirati različite segmente ispitanika prema elementima individualne sklonosti povjerenju. S tom se svrhom provela klaster analiza k-sredina, a uključene varijable su prethodno identificirani faktori. Sagledalo se nekoliko mogućih opcija odabira broja klastera, a kao optimalno rješenje odabrana je klaster analiza s tri segmenta. Rezultat analize su, dakle tri segmenta ispitanika koja se međusobno

razlikuju prema željenim varijablama. Sukladno tomu, segmenti imaju različita obilježja u smislu benevolentnosti, integriteta te stava povjerljivosti. Navedeno vodi do zaključka kako se hipoteza H4 prihvaća.

9. Ograničenja i implikacije istraživanja

9.1. Ograničenja

U slučaju analize teksta korištenjem aplikacije ParseHub preuzeti su korisnički osvrti za ispitivane kategorije proizvoda. Zbog ograničenja aplikacije, konkretno broja stranica s kojih je moguće preuzeti korisničke osvrte, odabrana je nekolicina proizvoda po kategoriji. Iz tog se razloga analiza provela na relativno malom uzorku, iako se u sklopu pojedinih datoteka s osvrtima nakon preliminarnih koraka obrade teksta nalazilo nekoliko desetaka tisuća atributa. Analiza je dala rezultate dostatne za donošenje odluke o podržavanju/odbacivanju hipoteze, ali adekvatno testiranje je potrebno provesti na većem uzorku sistematično odabranih artikala i usluga. Također, obzirom da je Amazon relativno nedavno u svoju ponudu uključio i usluge, njihov je broj manji nego što je to slučaj s proizvodima. Posljedično, dostupno je i mnogo manje korisničkih osvrta i nastavno manji uzorak osvrta za proizvode s karakteristikom povjerenja. Dodatno, kako programska rješenja za rudarenje teksta ne pružaju podršku za hrvatski jezik, analiza je provedena na engleskom jeziku pa se iz tog razloga rezultati ne mogu generalizirati za hrvatsko tržište.

Analiza temeljena na anketnom upitniku distribuiranom online uvijek za sobom nosi pitanje reprezentativnosti uzorka te iskrenosti ispitanika. Konkretno, istraživanje je provedeno na namjernom prigodnom uzorku, dok bi prihvatljivije bilo formirati kvote prema određenim parametrima. Također, ispitanicima je prezentiran proizvod s različitim osvrtima kako bi se testirala percipirana vjerodostojnost osvrta i autora. U idealnim uvjetima anketni upitnik bi se distribuirao trima različitim skupinama ispitanika, kako bi se izbjegao utjecaj prethodno pročitanog osvrta. Iako se razdvajanjem upitnika na cjeline te uvjetovanjem popunjavanja jednog dijela za prelazak na naredni nastojao minimizirati, mogućnost takvog utjecaja ipak postoji. Rezultati istraživanja usprkos svojoj statističkoj značajnosti ne mogu biti temelj generalizacije zaključaka na populaciju, obzirom da je istraživanje provedeno na namjernom prigodnom uzorku.

9.2. Implikacije rezultata istraživanja

Primjenom metode analize teksta i analize sentimenta uspješno su identificirani sentimenti korisničkih osvrta, kao i njihova subjektivnost. Dodatno, dobio se uvid u sentimente pojedinih fraza i riječi. Spomenute analize omogućuju kvantifikaciju verbalnog izražaja, a što je od izrazitog značaja za razumijevanje ponašanja potrošača. Prednost u odnosu na tradicionalne metode ogleda se u tome što se umanjuje utjecaj ljudske greške u istraživanjima, obzirom da pojedinac ne zna da je zapravo ”ispitanik” te se skriven iza svog korisničkog nadimka osjeća slobodnim izraziti svoje mišljenje. S druge strane, uz kvalitetnu pripremu, odabir stranica s kojih će se tekst prikupljati, ciljanog obujma teksta te odabir adekvatne aplikacije za prikupljanje, umanjuje se i greška istraživača. Dobiveni rezultati stoga daju nepristrani uvid u razmišljanje i stavove kupaca te se u kombinaciji s klasičnim metodama istraživanja mogu dobiti rezultati od značajne vrijednosti. Koristi od primjene ovih metoda imaju i poduzeća, bilo u istraživanju tržišta, bilo u praćenju aktivnosti konkurencije. Moguće je pratiti službene stranice konkurencije, online trgovine na kojima su ponuđeni njihovi proizvodi i slično te tako identificirati način na koji ih potrošači percipiraju. Spomenute rezultate kasnije mogu usporediti s vlastitim te doći do konkretnih informacija o poziciji u odnosu na konkurenciju te identificirati područja za napredak. Također, poduzeća korištenjem analize teksta i sentimenta mogu dobiti i uvid poteškoće s kojima se njihovi kupci susreću u korištenju proizvoda. Navedeno je konkretno dokazano na primjeru fraza *simple_plug, feel_batteri* te *professional_from,* gdje je prva spominjana pretežno u negativnom kontekstu što sugerira kako su korisnici nezadovoljni tim dijelom proizvoda, a što poduzeću pruća priliku za poboljšanja. S druge strane, prikaz sentimenta za frazu *feel_batteri* pokazuje kako su kupci ili jako zadovoljni ili jako nezadovoljni baterijom proizvoda. Iz navedenog proizlazi kako prilikom oblikovanja proizvoda tomu treba pružiti posebnu pažnju. Sličan je slučaj i s *professional_from* koja se odnosi na pružene usluge, odnosno osoblje zaduženo za iste.

Rezultati istraživanja komponenti individualne sklonosti povjerenju su pokazali kako se korisnički osvrti koji se referiraju na pozitivne i negativne strane proizvoda percipiraju vjerodostojnijim od onih u kojima su sadržani isključivo pozitivni ili negativni komentari. Navedeno sugerira kako je potencijalnim kupcima važno u potpunosti procijeniti proizvod te stoga one osvrte koji se fokusiraju na sve karakteristike proizvoda, bez korištenja superlativa, smatraju vjerodostojnim. Implikacije su značajne za poduzeća koja se u promociji svojih proizvoda koriste utjecajnim osobama, influencerima, sponzoriranim člancima i sličnim oblicima marketinške

komunikacije. Naime, prema saznanjima ovog istraživanja, ukoliko putem takvih kanala plasiraju informacije o prednostima i, u manjoj mjeri, manama potencijalni će ih kupci percipirati kao vjerodostojne. Također, dobiti će dojam realističnog prikaza proizvoda, što s adekvatno oblikovanom prodajnom propozicijom povećava vjerojatnost kupnje. Dodatno, ukoliko na službenim web stranicama imaju integriranu i online trgovinu s mogućnošću ostavljanja osvrta, mogu istaknuti osvrte s uključenim pozitivnim i negativnim stranama kako bi prvi bili uočeni.

Jedan od ciljeva ovog istraživanja bio je identificirati segmente prema individualnoj sklonosti povjerenja, što je uspješno ostvareno. Segmenti se razlikuju prema svom pristupu okolini, odnosno svim subjektima s kojima su u interakciji. Navedeno je indikativno za poduzeća koja pomoću segmentacije svog ciljnog tržišta putem individualnih karakteristika mogu steći značajne konkurentne prednosti. Spoznajom karakteristika svojih kupaca moguće je kreirati jedinstven pristup kroz oblikovanje komunikacije s odgovarajućim apelima, jer je iz rezultata ovog istraživanja razvidno kako pripadnici različitih segmenata imaju različite prioritete u komunikaciji. Kroz poznavanje svojih kupaca, odnosno onih elemenata komunikacije na koje pozitivno reagiraju, moguće je kreirati efikasan sustav odgovora na pritužbe koji će minimizirati negativne efekte. Uz kvalitetnu analizu svoje korisničke baze moguće je stoga doći do konkretnih načina kojim će se osigurati dugoročna lojalnost kupaca.

10. Naznake za buduća istraživanja

Kako je spomenuto, jedno od ograničenja ovog istraživanja jest relativno malen uzorak prikupljenih korisničkih osvrta. U budućim istraživanjima bi se analiza trebala ponoviti na većem uzorku te usporediti rezultate. Analizu je moguće i proširiti te kombinirati tekst osvrta s prosječnim ocjenama sustava zvjezdica kako bi se utvrdila podudarnost među njima, kao i najčešće fraze koje se koriste prema ocjenama. Postojeće istraživanje ostavlja prostor i za produbljivanje analize u smislu kreiranja asocijacija riječi te detaljne analize učestalosti fraza za pojedine proizvode kako bi se stekao uvid u prioritete kupaca. Kombinirajući rezultate takve dubinske analize s analizom sentimenta donijeli bi se precizni zaključci o načinu na koji kupci vrednuju pojedine karakteristike proizvoda te kako vrednovano izražavaju. Na taj način se mogu identificirati uzorci ponašanja potrošača i prema fazama životnog ciklusa proizvoda, što ima dodatnu istraživačku i praktičnu vrijednost.

Kako je prethodno spominjano, jedno od ograničenja ovog istraživanja je nemogućnost prikupljanja podataka anketnim upitnikom na tri različite skupine. Korekcijom spomenutog, došlo bi se do vjerodostojnijih rezultata. Pri tom, tijekom procesa uzorkovanja u slučaju unapređenja ovog istraživanja, potrebno je i identificirati karakteristike uzorka koje bi bile adekvatan reprezentant populacije. Spomenutim bi se i rezultati istraživanja mogli generalizirati.

Kako bi se unaprijedio regresijski model, preporučljivo je formirati cjelovit model povjerenja s više uključenih njegovih komponenti. Pretpostavka je da bi se time riješio problem nedostatnog koeficijenta determinacije.

11. Zaključak

Prije tek dva desetljeća pod pojmom e-trgovinom podrazumijevala se kupoprodaja jednostavnih proizvoda uz statične vizualne oglase te, s današnjeg gledišta, rudimentarne tražilice. Danas je na digitalnom tržištu moguće provesti transakcije koje uključuju i kompleksne proizvode te stručne usluge. Kupac više nije ograničen na lokalno tržište, već ima pristup ponuditeljima željenog proizvoda iz cijelog svijeta pri čemu bez ulaganja puno truda i vremena može procijeniti alternative te donijeti konačan odabir. Jedna od karakteristika globalnog tržišta je sve jača i brojnija konkurencija. Razvili su se modaliteti online tržišta koji se razlikuju prema subjektima koji na istima djeluju te platformama koje omogućuju provođenje transakcija: B2C, gdje poslovni subjekti nude svoje proizvode i usluge krajnjim kupcima; B2B na kojem se transakcije odvijaju među poslovnim subjektima; C2C gdje se razmjena odvija među krajnjim korisnicima; mobilna e-trgovina, tj. provođenje transakcija putem pametnih mobilnih uređaja; lokalna e-trgovina koja se temelji na informacijama o trenutnoj lokaciji kupca te mu shodno tomu nudi usluge u njegovoj blizini te društvena e-trgovina, odnosno integracija sustava za e-trgovinu s društvenim mrežama. Potonji je modalitet naročito značajan jer predstavlja konvergenciju dvaju načina i oblika korištenja internetskih usluga. Naime, društvene mreže kao što su Facebook i Instagram provode integraciju s platformama za e-trgovinu te tako uklapaju prodajne ponude poduzeća u već poznato iskustvo korištenja društvenih mreža. Time, korisnicima se prilikom svakodnevnog pregleda društvenih mreža, među objavama svojih prijatelja i pratitelja plasiraju objave poduzeća koje sadržajem ne odstupaju od klasičnih objava, osim što je moguće direktno iz aplikacije obaviti transakciju. Značaj spomenutog leži i u činjenici kako društvene mreže pružaju korisnicima jednostavnu mogućnost

ostavljanja osvrta, izražavanja zadovoljstva i nezadovoljstva te pristup osvrtima drugih te tako direktno utječu na proces donošenja kupovne odluke.

Kupcima su, dakle, dostupni proizvodi iz cijelog svijeta, putem više platformi te jednostavno mogu usporediti cijene, odnosno razmjer cijene i kvalitete. Dodatne pogodnosti, kao što su besplatna ili dostava niske cijene, činjenica da kupnju mogu obaviti iz svog doma te u bilo koje doba dana, doveli su do toga da gotovo 70% građana EU kupuje online. Međutim, uz sve pogodnosti online trgovine, javljaju se i izvjesni rizici, od kojih su neki specifični isključivo za ovaj tip trgovine kao što su rizik financijskih transakcija, dostave proizvoda, adekvatne kvalitete i slično. Uz to, prisutni su i rizici već poznati u marketinškoj literaturi – funkcionalni, vremenski, psihološki i društveni.

Kada su suočeni sa spomenutim percipiranim rizicima, kupci se koriste strategijama redukcije istih. Potencijalni se kupci stoga upuštaju u prikupljanje informacija o proizvodima i prodavačima putem njihovih službenih komunikacijskih kanala te se oslanjaju na iskustva drugih kupaca. Iskustva drugih kupaca se prenose u obliku usmene predaje, pri čemu je prije razvoja digitalnih kanala kupac bio ograničen na svoj uži društveni krug. Danas ima pristup mišljenjima svih kupaca koji su voljni javno objaviti svoje iskustvo korištenja, odnosno konzumacije proizvoda. Riječ je o neformalnoj komunikaciji između potrošača koja direktno utječe na uspjeh proizvoda te je stoga jasno kako je usmena predaja od izrazitog značaja za poduzeća.

Dakle, razvojem interneta potrošačima je pružena mogućnost dijeljenja svoja mišljenja i iskustva o brandovima, poduzećima i proizvodima. Istraživanja su pokazala različita mišljenja o tome što motivira usmenu predaju, bilo da se radi o osobnim karakteristikama, zadovoljstvu ili nezadovoljstvu te način na koji se izražavaju ovisno o tipu proizvoda/usluge, poduzeću i slično. Kategorije proizvoda s karakteristikom pretraživanja, iskustva i povjerenja imaju različita obilježja, nije ih jednako jednostavno procijeniti prije kupnje te ih kupci drugačije i vrednuju. Prema tome, prilikom pisanja osvrta za proizvode s karakteristikom povjerenja pretpostavka je kako će se korisnici uglavnom koristiti objektivnim izrazima, koji se odnose na obilježja proizvoda. Na drugom kraju spektra su proizvodi s karakteristikom povjerenja koje je teško procijeniti i nakon korištenja te se stoga pretpostavlja da je iskustvo proizašlo iz njihove komunikacije pretežito opisano preko osobnih dojmova, tj. subjektivnim izrazima. Navedeno je ovo istraživanje u izvjesnoj mjeri i dokazalo. Naime, osvrti za proizvode s karakteristikom povjerenja se značajno razlikuju od onih za proizvode s karakteristikom traženja i iskustva, pri čemu su svi ispitivane

skupine osvrta bile značajno subjektivne. Također, rezultati su pokazali kako se korisnici prilikom pisanja osvrta za proizvode s karakteristikom iskustva koriste i subjektivnim i objektivnim izrazima.

Kako je bilo govora, u slučaju da se kupac odluči za pisanje osvrta, potpuno zadovoljstvo će rezultirati pozitivnim korisničkim osvrtom, nezadovoljstvo negativnim, a nepotpuno osvrtom s pozitivnim i negativnim elementima. Međutim, treba napomenuti kako su zabilježeni slučajevi u kojima su sama poduzeća pisala pozitivne osvrte za svoje proizvode, dok su istovremeno nastojala narušiti ugled konkurencije negativnim osvrtima te su za isto plaćale pojedince voljne za pisanje lažnih osvrta. Tako prema istraživanju ReviewTrackers čak 79% ispitanika u 2017. godini smatra kako je pročitalo lažni osvrt, dok ih 16% smatra kako uvijek mogu uočiti radi li se o lažnom osvrtu. Stoga se postavlja pitanje vjeruju li potencijalni kupci više pozitivnim ili negativnim korisničkim osvrtima? Linearno razmišljanje jest da pozitivni osvrti vode većoj prodaji, dok je negativni umanjuju, što i nije primjenjivo na stvarno, kompleksno okruženje u kojem pojedinci djeluju. U pravilu, kupac će prije primijetiti negativan osvrt zbog tzv. sklonosti negativnosti jer je pojedinčevo okruženje karakterizirano pretežito pozitivnim signalima, zbog čega negativni signali, kao odmak od norme, privlače pozornost. Navedeno ne mora nužno biti loše sa stajališta poduzeća, jer prema nekim istraživanjima relativno manja proporcija negativnih osvrta može značiti da će potencijalni kupac lakše uočiti proizvod. Također, negativni komentari u pretežito pozitivnom osvrtu mogu biti signal vjerodostojnosti. Navedeno je podržano i ovim istraživanjem koje je pokazalo kako su korisnički osvrti s miješanim sentimentima percipirani vjerodostojnijim od onih koji su isključivo pozitivni ili negativni.

U prevladavanju osjećaja nesigurnosti proizašlih iz percipiranih rizika ključnu ulogu ima povjerenje. U literaturi se spominje više klasifikacija povjerenja, međutim u procjeni percipirane vjerodostojnosti korisničkih osvrta pretpostavka je kako će individualne karakteristike biti od presudnog značaja. Prema McKnight i sur. (2002) individualna sklonost povjerenju je određena konstruktima benevolentnosti, integriteta te stava povjerljivosti. Navedeni su bili ispitivani ovim istraživanjem te je pokazano kako benevolentnosti i stav povjerljivosti imaju statistički značajan pozitivan utjecaj na percipiranu vjerodostojnost. Integritet nije imao statistički značajan utjecaj, što zajedno s relativno niskim koeficijentom determinacije tek djelomično potvrđuje hipotezu. Navedeno bi se moglo korigirati uključivanjem drugih konstrukata povjerenja u model.

Obzirom na kompleksnost povjerenja te individualne razlike u njemu, razumno je pretpostaviti kako će se moći izdvojiti segmenti prema istom. Klaster analizom su identificirana tri segmenta s različitim intenzitetom pojedinih komponenti povjerenja - *povjerljivi sa zadrškom, dobroćudni skeptici* te *integritet i predrasude.* Prema tvrdnjama iz anketnog upitnika moguće je donijeti zaključke o različitom pristupu drugim ljudima te očekivanjima od njih.

Sažetak

Digitalno doba je donijelo promjene u svakodnevici, uključujući i način na koji ljudi kupuju. Razvoj online trgovina, a odnedavno i integracija kupovine u iskustvo korištenja društvenih mreža, proizvode i usluge čine dostupnijim nego prije. S druge strane, kupac ima veći pristup informacijama o proizvodima i poduzećima, bilo službenim ili onim proizašlim od strane drugih korisnika. Također, kupac ima priliku biti i izvor informacija kroz pisanje korisničkih osvrta, za što na raspolaganju ima niz specijaliziranih platformi i društvenih mreža. Online trgovina ipak ima određene specifičnosti u odnosu na klasičnu, od nemogućnosti stvarnog doživljaja proizvoda, odnosno fizičkog kontakta do nesigurnosti vezanih uz dostavu proizvoda, sigurnost plaćanja i zaštitu privatnosti. Drugim riječima, javljaju se rizici u čijem nadilaženju značajnu ulogu ima povjerenje, tj. psihološko stanje koje sadrži namjeru prihvaćanja ranjivosti temeljenu na pozitivnim očekivanjima namjere ponašanja druge strane. Povjerenje u kontekstu online trgovine je istraženo metodom analize sentimenta korisničkih osvrta te prikupljanjem podataka putem anketnog upitnika. Rezultati analize teksta korisničkih osvrta pokazali su kako je moguće definirati razlike u njihovoj objektivnosti obzirom na kategoriju proizvoda. Pri tome, utvrđeno je kako su osvrti za proizvode s karakteristikom pretraživanja i iskustva djelomično subjektivni, dok su za proizvode s karakteristikom povjerenja u potpunosti subjektivni, čime su djelomično potvrđene pretpostavke istraživanja. Dodatno, dobio se uvid u prevladavajući sentiment pojedinih fraza izoliranih putem analize teksta. Nadalje, empirijskim istraživanjem temeljem podataka anketnog upitnika pokazano je kako postoje razlike percipiranoj vjerodostojnosti korisničkih osvrta ovisno o tome jesu li oni pozitivni ili negativni, odnosno sadrže li i pozitivne i negativne komentare. Ispitivan je i utjecaj komponenti individualne sklonosti povjerenju, benevolentnosti, integriteta i stava povjerljivosti, na percipiranu vjerodostojnost komunikacije putem regresijske analize. Konačno, identificirani su i segmenti ispitanika prema pojedinim komponentama povjerenja, a koji se prema istima razlikuju.

Ključne riječi: e-trgovina, povjerenje, analiza sentimenta, benevolentnost, integritet, stav povjerljivosti

Summary

Digital age has caused shifts in everyday life, including the way people shop. Development of online shops, and as of recently their integration in social media outlets (such as Instagram), makes products and services more available than ever before. On the other side there is a customer who has more access to the information about products and companies, whether those information are official or otherwise, such as user reviews. Also, customer has the opportunity to become a source of information himself, having the plethora of specialized platforms and social media at his disposal. E-commerce has several differences in comparison with classical shopping experience, for example the inability to physically see and feel the product, insecurities regarding the delivery, payment safety and protection of privacy. In other words, in e-commerce a customer may experience more insecurities and perceived risks and trust has a significant role in overcoming those risks. Trust can be defined as a psychological state with the intention of accepting vulnerability due to the positive expectations of the other sides behaviour. Trust in the context of e-commerce has been explored via sentiment analysis of consumer reviews and by collecting the data from the sample using a questionnaire. Results of the consumer reviews text analysis for different product categories have shown that it is possible to notice the differences in their perceived objectivity. It has been determined that reviews for search and experience goods are partly objective, while reviews for credence goods are subjective in their entirety, only partially confirming the assumptions. Furthermore, empirical research on the data collected by questionnaire has shown that there are significant differences in perceived credibility of consumer reviews in respect to their contained positivity and negativity. Influence of the components of disposition to trust on perceived credibility has been analysed with regression analysis. Finally, using cluster analysis, three different segments of users have been identified regarding the components of disposition to trust – benevolence, integrity and trusting stance.

Keywords: e-commerce, trust, sentiment analysis, benevolence, integrity, trusting stance

Izvori

1. 2018 ReviewTrackers Online Reviews Survey: Statistics and Trends, ReviewTrackers, 2018, https://www.reviewtrackers.com/online-reviews-survey/#
2. 85% Hrvata kupuje online, a beskontaktno plaća 59% korisnika kartica, Netokracija 2017, https://www.netokracija.com/masterindex-hrvatska-2017-istrazivanje-138428
3. Akyüz, A. (2013). Determinant factors influencing eWOM. *Mediterranean Journal of Social Sciences*, *4*(11), 159
4. Anderson, E. W. (1998). Customer satisfaction and word of mouth. *Journal of service research*, *1*(1), 5-17.
5. Baron, J. P., Shaw, M. J., & Bailey Jr, A. D. (2000). Web-based e-catalog systems in B2B procurement. *Communications of the ACM*, *43*(5), 93-100.
6. Bart, Y., Shankar, V., Sultan, F., & Urban, G. L. (2005). Are the drivers and role of online trust the same for all web sites and consumers? A large-scale exploratory empirical study. *Journal of marketing*, *69*(4), 133-152.
7. Berger, J. (2014). Word of mouth and interpersonal communication: A review and directions for future research. *Journal of Consumer Psychology*, *24*(4), 586-607.
8. Brooks, R. C. (1957). " Word-of-Mouth" Advertising in Selling New Products. *Journal of Marketing*, *22*(2), 154-161.
9. Brown, J. J., & Reingen, P. H. (1987). Social ties and word-of-mouth referral behavior. *Journal of Consumer research*, *14*(3), 350-362.
10. Buttle, F. A. (1998). Word of mouth: understanding and managing referral marketing. *Journal of strategic marketing*, *6*(3), 241-254.
11. Cao, Q., Duan, W., & Gan, Q. (2011). Exploring determinants of voting for the "helpfulness" of online user reviews: A text mining approach. *Decision Support Systems*, *50*(2), 511-521
12. Chatterjee, P. (2001). Online reviews: do consumers use them?.
13. Chevalier, J. A., & Mayzlin, D. (2006). The effect of word of mouth on sales: Online book reviews. *Journal of marketing research*, *43*(3), 345-354.
14. Cui, G., Lui, H. K., & Guo, X. (2012). The effect of online consumer reviews on new product sales. *International Journal of Electronic Commerce*, *17*(1), 39-58.

15. Cullen, A. J., & Taylor, M. (2009). Critical success factors for B2B e-commerce use within the UK NHS pharmaceutical supply chain. *International Journal of Operations & Production Management*, *29*(11), 1156-1185.
16. Dellarocas, C. (2003). The digitization of word of mouth: Promise and challenges of online feedback mechanisms. *Management science*, *49*(10), 1407-1424.
17. Digital economy and society statistics – enterprises, Together Against Trafficking in Human Beings, Eurostat 2018, http://ec.europa.eu/eurostat/statistics-explained/index.php/Digital_economy_and_society_statistics_-_enterprises#Enterprises.E2.80.99_presence_on_the_internet
18. Doh, S. J., & Hwang, J. S. (2009). How consumers evaluate eWOM (electronic word-of-mouth) messages. *CyberPsychology & Behavior*, *12*(2), 193-197.
19. E-commerce analizator – najbolji hrvatski webshop po mišljenju developera, ecommerce.hr; 2018, https://ecommerce.hr/novosti/ecommerce-analizator-najbolji-hrvatski-webshop-po-misljenju-developera/
20. Ecommerce Software - Best Ecommerce Platform Made for You, Shopify 2018, https://www.shopify.com/
21. Ellison, G., & Fudenberg, D. (1995). Word-of-mouth communication and social learning. *The Quarterly Journal of Economics*, *110*(1), 93-125.
22. Fairley, K., Sanfey, A., Vyrastekova, J., & Weitzel, U. (2016). Trust and risk revisited. *Journal of Economic Psychology*, *57*, 74-85.
23. Fan, Y. W., & Miao, Y. F. (2012). Effect of electronic word-of-mouth on consumer purchase intention: The perspective of gender differences. *International Journal of Electronic Business Management*, *10*(3), 175.
24. Field, A. (2006). *Discovering statistics using SPSS*. Sage publications.
25. Garbarino, E., & Johnson, M. S. (1999). The different roles of satisfaction, trust, and commitment in customer relationships. *the Journal of Marketing*, 70-87.
26. Gefen, D., Karahanna, E., & Straub, D. W. (2003). Trust and TAM in online shopping: An integrated model. *MIS quarterly*, *27*(1), 51-90
27. Geyskens, I., Steenkamp, J. B. E., Scheer, L. K., & Kumar, N. (1996). The effects of trust and interdependence on relationship commitment: A trans-Atlantic study. *International Journal of research in marketing*, *13*(4), 303-317.

28. Ghose, A., & Ipeirotis, P. G. (2011). Estimating the helpfulness and economic impact of product reviews: Mining text and reviewer characteristics. *IEEE Transactions on Knowledge and Data Engineering*, *23*(10), 1498-1512.
29. Goffman, E. (2002). The presentation of self in everyday life. 1959. *Garden City, NY*.
30. Hennig-Thurau, T., Gwinner, K. P., Walsh, G., & Gremler, D. D. (2004). Electronic word-of-mouth via consumer-opinion platforms: what motivates consumers to articulate themselves on the internet?. *Journal of interactive marketing*, *18*(1), 38-52.
31. Hennig-Thurau, T., Walsh, G., & Walsh, G. (2003). Electronic word-of-mouth: Motives for and consequences of reading customer articulations on the Internet. *International journal of electronic commerce*, *8*(2), 51-74.
32. Hu, N., Bose, I., Koh, N. S., & Liu, L. (2012). Manipulation of online reviews: An analysis of ratings, readability, and sentiments. *Decision Support Systems*, *52*(3), 674-684.
33. Hu, N., Liu, L., & Zhang, J. J. (2008). Do online reviews affect product sales? The role of reviewer characteristics and temporal effects. *Information Technology and management*, *9*(3), 201-214.
34. Internet advertising of businesses - statistics on usage of ads; Together Against Trafficking in Human Beings, Eurostat 2018, http://ec.europa.eu/eurostat/statistics-explained/index.php/Internet_advertising_of_businesses_-_statistics_on_usage_of_ads
35. Ivanov, A. E. (2012). The Internet‘s impact on integrated marketing communication. *Procedia Economics and Finance*, *3*, 536-542.
36. Jones, Q., Ravid, G., & Rafaeli, S. (2004). Information overload and the message dynamics of online interaction spaces: A theoretical model and empirical exploration. *Information systems research*, *15*(2), 194-210.
37. Keller, E., & Fay, B. (2009). The role of advertising in word of mouth. *Journal of Advertising Research*, *49*(2), 154-158.
38. Kim, C., Zhao, W., & Yang, K. H. (2008). An empirical study on the integrated framework of e-CRM in online shopping: evaluating the relationships among perceived value, satisfaction, and trust based on customers' perspectives. *Journal of Electronic Commerce in Organizations (JECO)*, *6*(3), 1-19.

39. Kim, D. J., Ferrin, D. L., & Rao, H. R. (2008). A trust-based consumer decision-making model in electronic commerce: The role of trust, perceived risk, and their antecedents. *Decision support systems*, *44*(2), 544-564.
40. Koufaris, M., & Hampton-Sosa, W. (2004). The development of initial trust in an online company by new customers. *Information & management*, *41*(3), 377-397.
41. Kusumasondjaja, S., Shanka, T., & Marchegiani, C. (2012). Credibility of online reviews and initial trust: The roles of reviewer's identity and review valence. *Journal of Vacation Marketing*, *18*(3), 185-195.
42. Lau, G. T., & Ng, S. (2001). Individual and situational factors influencing negative word-of-mouth behaviour. *Canadian Journal of Administrative Sciences/Revue Canadienne des Sciences de l'Administration*, *18*(3), 163-178.
43. Laudon, K. C., & Traver, C. G. (2013). *E-commerce*. Pearson.
44. Lee, J., Park, D. H., & Han, I. (2008). The effect of negative online consumer reviews on product attitude: An information processing view. *Electronic commerce research and applications*, *7*(3), 341-352.
45. Li, X., & Hitt, L. M. (2008). Self-selection and information role of online product reviews. *Information Systems Research*, *19*(4), 456-474.
46. Local Consumer Review Survey;Online Reviews Statistics & Trends, BrightLocal, 2017; https://www.brightlocal.com/learn/local-consumer-review-survey/
47. Ludwig, S., De Ruyter, K., Friedman, M., Brüggen, E. C., Wetzels, M., & Pfann, G. (2013). More than words: The influence of affective content and linguistic style matches in online reviews on conversion rates. *Journal of Marketing*, *77*(1), 87-103.
48. MacKinnon, K. A. (2012). User Generated Content vs. Advertising: Do Consumers Trust the Word of Others Over Advertisers?. *The Elon Journal of Undergraduate Research in Communications*, *3*(1), 14-22.
49. McKnight, D. H., & Chervany, N. L. (2001). Trust and distrust definitions: One bite at a time. In *Trust in Cyber-societies* (pp. 27-54). Springer, Berlin, Heidelberg.
50. McKnight, D. H., Choudhury, V., & Kacmar, C. (2002). Developing and validating trust measures for e-commerce: An integrative typology. *Information systems research*, *13*(3), 334-359.

51. McKnight, D. H., Choudhury, V., & Kacmar, C. (2002). The impact of initial consumer trust on intentions to transact with a web site: a trust building model. *The journal of strategic information systems*, *11*(3-4), 297-323.
52. McKnight, D. H., Kacmar, C. J., & Choudhury, V. (2004). Shifting Factors and the Ineffectiveness of Third Party Assurance Seals: A two-stage model of initial trust in a web business. *Electronic Markets*, *14*(3), 252-266.
53. Metzger, M. J., & Flanagin, A. J. (2013). Credibility and trust of information in online environments: The use of cognitive heuristics. *Journal of Pragmatics*, *59*, 210-220.
54. Mirošević, I. (2017). k-means Algorithm. *KoG*, *20*(20), 91-98.
55. Mizerski, R. W. (1982). An attribution explanation of the disproportionate influence of unfavorable information. *Journal of Consumer Research*, *9*(3), 301-310.
56. Mukherjee, A., & Nath, P. (2007). Role of electronic trust in online retailing: A re-examination of the commitment-trust theory. *European Journal of Marketing*, *41*(9/10), 1173-1202.
57. Nicolaou, A. I., & McKnight, D. H. (2006). Perceived information quality in data exchanges: Effects on risk, trust, and intention to use. *Information systems research*, *17*(4), 332-351.
58. Oliveira, T., Alhinho, M., Rita, P., & Dhillon, G. (2017). Modelling and testing consumer trust dimensions in e-commerce. *Computers in Human Behavior*, *71*, 153-164.
59. Pan, L. Y., & Chiou, J. S. (2011). How much can you trust online information? Cues for perceived trustworthiness of consumer-generated online information. *Journal of Interactive Marketing*, *25*(2), 67-74.
60. Park, C., & Lee, T. M. (2009). Information direction, website reputation and eWOM effect: A moderating role of product type. *Journal of Business research*, *62*(1), 61-67.
61. Park, C., Wang, Y., Yao, Y., & Kang, Y. R. (2011). Factors influencing eWOM effects: Using experience, credibility, and susceptibility. *International Journal of Social Science and Humanity*, *1*(1), 74.
62. Park, D. H., & Kim, S. (2008). The effects of consumer knowledge on message processing of electronic word-of-mouth via online consumer reviews. *Electronic Commerce Research and Applications*, *7*(4), 399-410.

63. Richins, M. L. (1984). Word of mouth communication as negative information. *ACR North American Advances*.
64. Rozga, A. (2006). Statistika za ekonomiste. *Ekonomski fakultet Split, Split*.
65. Ryan, D. and Jones, C. (2009), *Understanding Digital Marketing: Marketing Strategies for Engaging the Digital Generation*, Marketing Industry Network, Glasgow.
66. Sen, S., & Lerman, D. (2007). Why are you telling me this? An examination into negative consumer reviews on the web. *Journal of interactive marketing*, *21*(4), 76-94.
67. Shankar, V., Urban, G. L., & Sultan, F. (2002). Online trust: a stakeholder perspective, concepts, implications, and future directions. *The Journal of strategic information systems*, *11*(3-4), 325-344.
68. Social media - statistics on the use by enterprises; Together Against Trafficking in Human Beings, Eurostat 2018, http://ec.europa.eu/eurostat/statistics-explained/index.php/Social_media_-_statistics_on_the_use_by_enterprises#Use_of_social_media:_highlights
69. Sparks, B. A., & Browning, V. (2011). The impact of online reviews on hotel booking intentions and perception of trust. *Tourism management*, *32*(6), 1310-1323.
70. Sundaram, D. S., Mitra, K., & Webster, C. (1998). Word-of-mouth communications: A motivational analysis. *ACR North American Advances*.
71. Sweeney, J. C., Soutar, G. N., & Mazzarol, T. (2008). Factors influencing word of mouth effectiveness: receiver perspectives. *European journal of marketing*, *42*(3/4), 344-364
72. Text Mining & Sentiment Analysis, RapidMiner© 2018, http://rapidminer.com
73. Top Ecommerce Platforms Market Share in 2017, The Official Cloudways Blog 2017, https://www.cloudways.com/blog/top-ecommerce-platforms/
74. Utz, S. (2009). 'Egoboo'vs. altruism: the role of reputation in online consumer communities. *new media & society*, *11*(3), 357-374.
75. Utz, S. (2009). Rebuilding trust after negative feedback: the role of communication. *eTrust: Forming relationships in the online world*, 238-265.
76. Utz, S., Kerkhof, P., & van den Bos, J. (2012). Consumers rule: How consumer reviews influence perceived trustworthiness of online stores. *Electronic Commerce Research and Applications*, *11*(1), 49-58.

77. Utz, Sonja, Uwe Matzat, and Chris Snijders. "On-line reputation systems: The effects of feedback comments and reactions on building and rebuilding trust in on-line auctions." *International Journal of Electronic Commerce* 13.3 (2009): 95-118.
78. Vancouver Data Blog by Neil McGuigan, Text Analytics with RapidMiner, 2010, http://vancouverdata.blogspot.com/2010/11/text-analytics-with-rapidminer-loading.html
79. Verčič, A. T., Sinčić, D., & Vokić, N. P. (2010). *Priručnik za metodologiju istraživačkog rada: kako osmisliti, provesti i opisati znanstveno i stručno istraživanje*. MEP.
80. Victor, P., Cornelis, C., De Cock, M., & Teredesai, A. (2009). Trust-and distrust-based recommendations for controversial reviews. In *Web Science Conference (WebSci'09: Society On-Line)* (No. 161).
81. Video Tutorial: Scraping a List of Keywords, ParseHub Help Center, 2018, https://www.parsehub.com
82. Wang, Y., & Rodgers, S. (2010). Electronic word of mouth and consumer generated content: From concept to application. *Handbook of research on digital media and advertising: user generated content consumption, edited by Matthew S. Eastin, et al*, 212-231.
83. Woodside, A. G., & Delozier, M. W. (1976). Effects of word of mouth advertising on consumer risk taking. *Journal of advertising*, *5*(4), 12-19.
84. Yin, D., Bond, S., & Zhang, H. (2013). Anxious or angry? Effects of discrete emotions on the perceived helpfulness of online reviews.

POPIS SLIKA I TABLICA

Slika 1. Najkorišteniji oblici ciljanog prikazivanja u Europi, 2017 – str. 16

Slika 2. Model online korisničkog ponašanja – str. 33

Slika 3. Prepreke online kupovini – str. 35

Slika 4. Najpopularnije stranice s korisničkim osvrtima – str. 53

Slika 5. Utjecaj korisničkih osvrta na donošenje odluke – str. 53

Slika 6. Koraci nakon čitanja korisničkog osvrta – str. 54

Slika 7. Čitanje korisničkih osvrta kao procjene poduzeća – str. 54

Slika 8. Utjecaj korisničkih osvrta na mišljenje o poduzeću – str. 55

Slika 9. Karakteristike osvrta na koje se obraća pozornost prilikom čitanja – str. 56

Slika 10. Odgovori poduzeća na osvrte – str. 57

Slika 11. Očekivanja korisnika o odogovorima na osvrte – str. 57

Slika 12. Broj pročitanih osvrta potrebnih za formiranje povjerenja – str. 58

Slika 13. Povjerenje u korisničke osvrte i osobne preporuke – str. 59

Slika 14. Učestalost pisanja korisničkih osvrta – str. 60

Slika 15. Mogućnost primjećivanja lažnih osvrta – str. 61

Slika 16. Učestalost lažnih osvrta – str. 61

Slika 17. Stranice na kojima se najčešće čitaju korisnički osvrti – str. 62

Slika 18. Prosječna ocjena kojoj korisnici najviše vjeruju – str. 62

Slika 19. Promjena duljine korisničkih osvrta 2010 – 2017 – str. 63

Slika 20. Distribucija korisničkih osvrta prema platformama 2015 – 2017 – str. 64

Slika 21. Promjena prosječne ocjene kroz vrijeme – str. 64

Slika 22. ParseHub određivanje narebi za prikupljanje korisničkih osvrta – str. 79

Slika 23. Učitavanje dokumenata u RapidMiner i definiranje glavnog procesa – str. 84

Slika 24. Definiranje podprocesa unutar operatora Process Documents – str. 85

Slika 25. Uvođenje operatora Analyze Sentiment – str. 86

Slika 26. Odnos sentimenata za fraze item_custom (1), simple_plug (2) i figure_complex (3 – str. 88

Slika 27. Odnos sentimenata za fraze outweigh (4), feel_batteri (5) i skilled_and (6) – str. 89

Slika 28. Odnos sentimenata za good_experi (7), great_deal (8) i professional_from (9) – str. 89

Slika 29. Scree test – str. 98

Slika 30. P - P graf standardiziranih reziduala – str. 104
Slika 31. Dijagram rasipanja regresijom standardiziranih predviđenih vrijednosti i standardiziranih reziduala – str. 105
Slika 32. Grafički prikaz faktora prema segmentima – str. 108
Tablica 1. Razlozi za online kupovinu – str. 24
Tablica 2. Spolna struktura uzorka – str. 82
Tablica 3. Dobna struktura uzorka – str. 82
Tablica 4. Rezultati analize sentimenta za dobra s karakteristikom pretraživanja – str. 87
Tablica 5. Rezultati analize sentimenta za dobra s iskustvenom karakteristikom – str. 87
Tablica 6. Rezultati analize sentimenta za proizvode s karakteristikom povjerenja – str. 88
Tablica 7. Test normalnosti distribucije indeksa percipirane vjerodostojnosti – str. 91
Tablica 8. Test razlike srednjih vrijednosti rangova za indekse percipirane vjerodostojnojnosti – str. 91
Tablica 9. Test normalnosti distribucije percipirane iskrenosti autora – str. 92
Tablica 10. Test razlike srednjih vrijednosti rangova percipirane iskrenosti autora osvrta – str. 93
Tablica 11. Test normalnosti distribucije percipirane vjerodostojnosti osvrta – str. 93
Tablica 12. Test razlike srednjih vrijednosti rangova percipirane vjerodostojnosti osvrta – str. 94
Tablica 13. Test normalnosti distribucije percipirane korisnosti osvrta – str. 95
Tablica 14. Test razlike srednjih vrijednosti rangova percipirane korisnosti osvrta – str. 96
Tablica 15. Preliminarna rotirana faktorska matrica – str. 97
Tablica 16. Kaiserov kriterij – str. 98
Tablica 17. Rotirana faktorska matrica - faktori uvršteni u analizu – str. 98
Tablica 18. Korelacijska matrica – str. 100
Tablica 19. Procjena regresijskog modela – str. 101
Tablica 20. Analiza varijance regresijskog modela – str. 101
Tablica 21. Parametri regresijskog modela – str. 101
Tablica 22. Procjena multikolinearnosti – str. 103
Tablica 23. Spearmanov koeficijent korelacije regresijskih varijabli i reziduala – str. 105
Tablica 24. Analiza varijance različitih opcija odabira broja klastera – str. 106
Tablica 25. Broj jedinki uzorka u klasterima za opcije odabira tri, četiri i pet klastera – str. 107
Tablica 26. Srednje vrijednosti faktora prema segmentima – str. 107

Dodaci

1. Ispitivanje percipirane vjerodostojnosti korisničkog osvrta

- Pozitivni korisnički osvrt

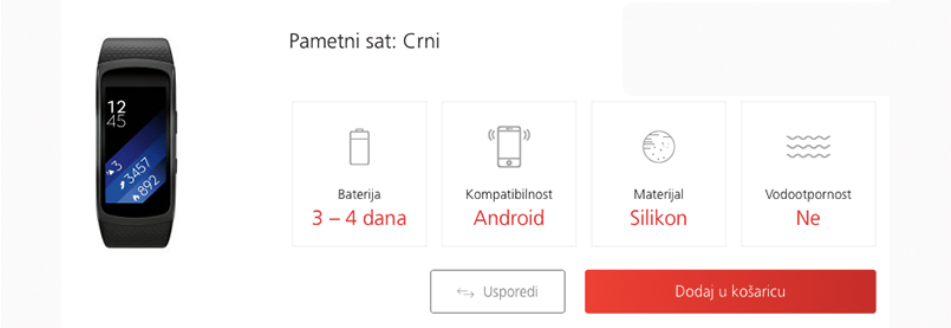

Mate Matić

Odličan proizvod

July 4, 2018

Color: Clear | Verified Purchase

Odličan smartwatch, glavni razlog kupnje bio je da ga nosim dok trčim. Mogu zvati i primati pozive, provjeravati i odgovarati na poruke, pratiti kako mi napreduje vježba, čak i slušati glazbu! U svakom pogledu korisno i mnogo bolje nego nositi mobitel sa sobom dok vježbam. Ostale funkcije, recimo štoperica i alarm također jako korisne! Nisam ni mogao vjerovati koliko će mi koristan pametni sat biti.

- Negativni korisnički osvrt

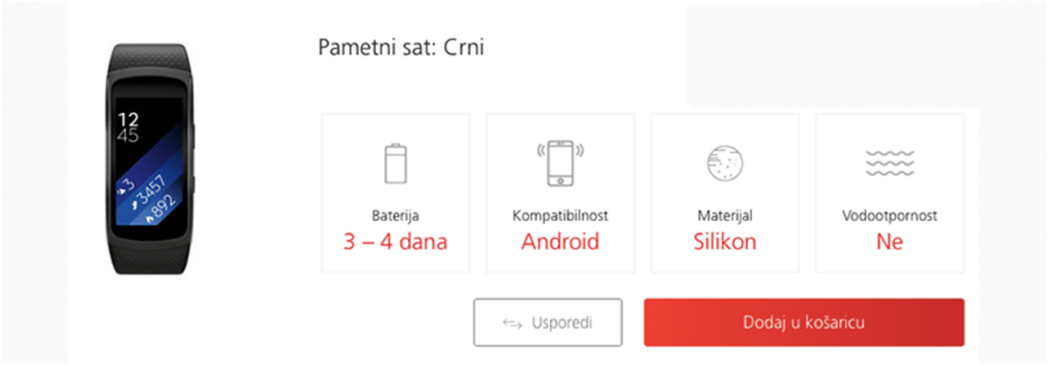

Mate Matić

Bačeni novci

August 24, 2018

Color: Silver1 | Verified Purchase

Kada bi bilo moguće, ovom bi satu dao i manje od jedne zvjezdice! Niti se mogao spojiti na telefon i kameru, a i nekako mi je preglomazan na ruci, treba biti elegantniji pogotovo kada pogledaš današnju tehnologiju! Ravno u smeće, jer je jefitnije nego poslati natrag!

- Osvrt s uključenim pozitivnim i negativnim komentarima

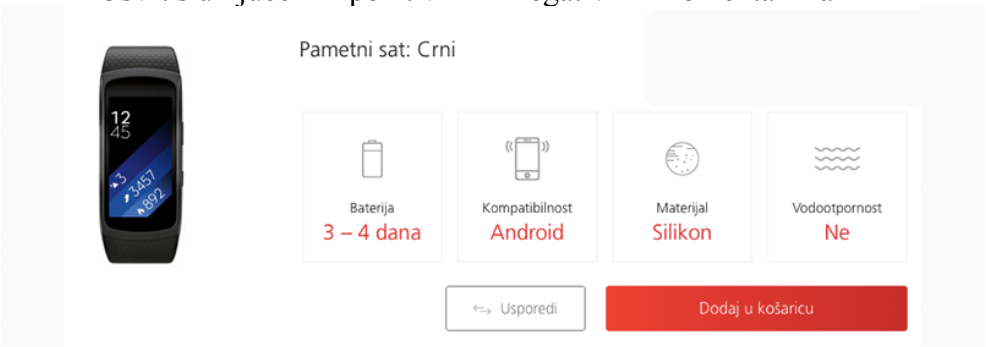

Mate Matić

Moglo je i gore...

September 4, 2018

Color: Black | Verified Purchase

Osnovne funkcije su u redu, jednostavno se spaja s mobitelom, čak je i kvaliteta izrade na nivou. Ali kada je riječ o naprednijim stvarima, pedometar je poprilično bazičan, nije na razini nekih fitness aplikacija, kao praćenje ritma sna. Za podešavanje sata se čovjek treba potruditi. Uglavnom, solidan proizvod, ali ima i boljih (doduše skupljih) pametnih satova.

- Tvrdnje kojima se ispitivala percipirana vjerodostojnost komunikacije

4. **Odaberite odgovor koji najviše odgovara Vašem stavu/mišljenju** *

Mark only one oval per row.

	Uopće se ne slažem	Ne slažem se	Djelomično se ne slažem	Djelomično se slažem	Slažem se	Potpuno se slažem
3.1. Autor komentara je bio iskren						
3.2. Korisnički osvrt realistično opisuje iskustvo korištenja ovim proizvodom						
3.3. Kada bi mi trebao pametni sat, ovaj bi mi osvrt bio koristan						
3.4. Kada bi mi trebao pametni sat, ovu stranicu bih uzeo/la u obzir za kupnju						
3.5. Kada bi mi trebao pametni sat, razmotrio/la bih ovaj model						

2. Ispitivanje komponenti individualne sklonosti povjerenju

- Korištene tvrdnje

	Uopće se ne slažem	Ne slažem se	Djelomično se ne slažem	Djelomično se slažem	Slažem se	Potpuno se slažem
4.1. Uglavnom, ljudima je stalo o dobrobiti drugih						
4.2. Tipična osoba vodi računa o problemima drugih ljudi						
4.3. U većini slučajeva, ljudima je stalo do drugih i žele biti od pomoći						
4.4. Uglavnom, ljudi vode računa samo o sebi						
4.5. U većini slučajeva ljudi ispune svoja obećanja						
4.6. Mislim da ljudi uglavnom nastoje djelima potkrijepiti svoju riječ						
4.7. Većina ljudi je iskrena u interakciji s drugima						
4.8. U većini slučajeva vjerujem ljudima dok mi ne daju razlog za suprotno						
4.9. Uglavnom ne donosim sud o ljudima kada ih tek upoznam						
4.10. Moj pristup ljudima je da im vjerujem sve dok mi svojim djelima ne pokažu da im se ne treba vjerovati						