

Tihana Škrinjarić*

JEL klasifikacija: G10, C32, G12
Prethodno priopćenje
<https://doi.org/10.32910/ep.72.1.1>

**MEĐUOVISNOST PRINOSA, RIZIKA I VOLUMENA
ONLINE PRETRAŽIVANJA TRŽIŠNOG INDEKSA:
PRISTUP PRELIJEVANJA ŠOKOVA
NA ZAGREBAČKOJ BURZI**

U ovome istraživanju razmatraju se vremenski promjenjiva međuovisnost i prelijevanje šokova između prinosa i rizika na službeni indeks Zagrebačke burze te volumena pretraživanja vezanog uz tržišni indeks na tražilici Google. Želi se ispitati kako investitorova pozornost mjerena volumenom pretraživanja može koristiti u modeliranju prinosa i/ili rizika službenog indeksa, ali se pritom dozvoljava i povratna veza prema volumenu pretraživanja. Za mjesečne podatke u razdoblju travanj 2004. – siječanj 2019. godine nalazi se vremenski promjenjiva međuovisnost svih triju varijabli, s povećanjem šokova prelijevanja u vrijeme financijske krize, kao i krize koncerna Agrokor (proljeće 2017. godine). Doprinos istraživanja očituje se u primjeni relativno nove metodologije indeksa prelijevanja šokova u okviru vektorskih autoregresijskih modela za razmatranje ovakve teme u literaturi. Temeljem rezultata istraživanja dane su okvirne smjernice potencijalnim investitorima za buduće primjene.

Ključne riječi: *pozornost investitora, Google pretraživanje, VAR, prinosi dionica, prelijevanje šokova*

* T. Škrinjarić, dr. sc., docent, Ekonomski fakultet, Zagreb (e-mail: tskrinjar@net.efzg.hr). Rad je primljen u uredništvo 20.04.2019. godine, a prihvaćen je za objavu 05.02.2020. godine.

1. UVOD

Posljednjih desetak godina u literaturi modeliranja prinosa i rizika dionica sve je popularniji pristup uz uključivanje *online* pretraživanja, s obzirom da se volumen pretraživanja na Internetu interpretira kao mjera investitorove pozornosti prema tržištu dionica (engl. *investor's attention*, vidjeti Da i dr., 2011). Takva skupina istraživanja pretpostavlja da je moguće prinose i/ili rizike dionica predviđati pomoću volumena pretraživanja na internetskim tražilicama, čime se narušava slabi oblik hipoteze efikasnog tržišta (engl. *Efficient Market Hypothesis*, Fama 1965, 1970). Osim što se volumen pretraživanja na internetu koristi u području financijskog modeliranja, postoje brojni radovi koji su pokazali kako se brojni ekonomski fenomeni mogu uspješnije modelirati i prognozirati uključivanjem volumena pretraživanja. Iako su istraživanja poput Merton (1987) te Sims (2003) ukazala na važnost investitorove pozornosti u vrednovanju dionica, revoluciju u financijskom modeliranju s uključivanjem internetskog volumena pretraživanja, a posebno *Google* pretraživanja, započeli su Mondria i dr. (2010) i Da i dr. (2011), gdje se razvijaju temelji za buduće analize, s obzirom na definiranje mjera volumena pretraživanja na Internetu kao mjere pozornosti investitora i njene alokacije. Jedan od teorijskih temelja čini Mertonov (1987) rad, u kojemu razvija model procjenjivanja kapitalne imovine uz pretpostavku kako investitori poznaju samo određen skup dionica. Zbog toga investitori nastoje držati one dionice u portfelju koje su im poznate, dok za novootkrivene dionice zahtijevaju veći prinos zbog većeg nesustavnog rizika. Posljedice ovog modela se očituju u povećanju vrijednosti takvih dionica na koje se sve više usmjerava pozornost investitora i smanjenju njihova očekivana prinosa (Lehavy i Sloan 2008). Da i dr. (2011) svoja razmatranja temelje na prethodnim nalazima, te nadograđuju na korištenje *Google* volumena pretraživanja kao dobre mjere investitorove pozornosti usmjerene prema dionicama. Nadodaju da se ovdje radi o individualnim investitorima (tzv. *noise traders*), koji nemaju toliko dostupne informacije o pojedinim dionicama poput institucionalnih. Prema modelima tržišne volatilnosti razvijenima u Lux i Marchesi (1999) te Alfarano i Lux (2007), takvi investitori uzrokuju dodatno povećanje volatilnosti na dioničkom tržištu.

Razlozi korištenja *Google* pretraživanja su opravdani u Da i dr. (2011), gdje se navodi kako je upravo ova najčešće korištena tražilica, te se radi o mjeri otkrivene pozornosti investitora (engl. *revealed attention measure*). Ovakve mjere dodatno su potaknute nalazima u Brooks (1998) te Donaldson i Kamstra (2005), gdje tradicionalne mjere pozornosti/interesa investitora poput volumena i prometa trgovanja nisu dovele do poboljšanja prognostičke moći modela prognoziranja prinosa i/ili rizika. Stoga se postavilo pitanje korisnosti volumena pretraživanja koje je za neke slučajeve moguće dobiti na tjednoj razini (ako se razmatraju američki podaci).

Zato ne čudi ubrzan porast ovakvih istraživanja u posljednjih nekoliko godina, pri čemu nakon područja medicine i bioloških znanosti na trećem mjestu prema primjenama i istraživanjima dolazi područje ekonomije (Jun i dr. 2018). Međutim, ono što se u literaturi uočava jest učestala pretpostavka kako je volumen pretraživanja egzogeno dana varijabla u modelu (najčešće se radi o ARMA, GARCH ili VAR modelima), iako je u, primjerice, Hamid i Heiden (2015) te u Vozlyublennaja (2014) utvrđena dvosmjerna uzročnost varijabli u modelu. Dakle, iako volumen pretraživanja može doprinijeti uspješnijem prognoziranju prinosa i/ili rizika dionica, postoji i povratna veza od prinosa i rizika prema *online* pretraživanju.

Doprinos ovog istraživanja u odnosu na postojeća očituje se u dvije stvari: prvo, analizira se i povratna veza od prinosa i rizika prema volumenu *online* pretraživanja s obzirom da većina istraživanja pretpostavlja samo jednosmjernu vezu od volumena pretraživanja prema riziku i/ili prinosu; što je u skladu s teorijom u Barber i dr. (2009), gdje u kratkome roku dolazi do povećanja volatilnosti zbog pritiska na cijene koje stvaraju investitori. Drugo, analizira se vremenski promjenjiva međuovisnost (vidjeti Bijl i dr. 2016) razmatranih varijabli na način da se procjenjuju promjenjivi indeksi prelijevanja šokova s obzirom na pomične prozore tijekom vremena. Stoga je ovo istraživanje eksplorativne naravi, kako bi se utvrdila dinamika i karakteristike prelijevanja šokova iz volumena, prinosa i rizika na Zagrebačkoj burzi. Na taj način će buduće analize usmjerene na prognoziranja imati temeljne smjernice. Za ostvarivanje svrhe ovoga istraživanja primjenjuje se metodologija indeksa prelijevanja šokova (engl. *Spillover index*) razvijena u Diebold i Yilmaz (2009, 2011, 2012) koja se nadograđuje u okviru VAR metodologije. Odabrana metodologija je prikladna s obzirom da se VAR modeli koriste za ispitivanje kratkoročne povezanosti između varijabli, što odgovara karakteristikama promjenjivosti dioničkih tržišta. Dodatno, doprinos razmatranja indeksa prelijevanja šokova očituje se u uvođenju dinamike u povezanosti odabranih varijabli, što je također prikladno za dionička tržišta.

Rezultati analize ukazuju na promjenjivost u prelijevanju šokova između varijabli prinosa i rizika CROBEX-a te *Google* volumena pretraživanja o indeksu CROBEX, što znači da se izmjenjuju razdoblja kada je pojedina varijabla neto primatelj ili davatelj šokova drugim varijablama u modelu. Robusnost rezultata je provjerena na nekoliko načina, stoga pouzdanost rezultata stvara temelje za buduće analize koje se komentiraju u diskusiji. Ostatak rada je sastavljen od sljedećih poglavlja. Drugo poglavlje daje pregled relevantnih istraživanja vezanih uz ovo, dok treće opisuje metodologiju rada. Četvrto poglavlje je empirijsko gdje se razmatraju glavni nalazi, robusnost rezultata i diskusija. Posljednje poglavlje zaključuje rad.

2. PREGLED LITERATURE

Teorijski pregled vezan uz temu ovog istraživanja dan je u sljedećim radovima. Najranije ideje sežu u 80-e godine 20. stoljeća, kada je Merton (1987) definirao hipotezu investitorova raspoznavanja (engl. *investor recognition hypothesis*): kako su investitori svjesni postojanja samo određenog broja dionica na burzama, tako u portfelju drže samo takve dionice, dok će one za koje trenutno nisu svjesni, u budućnosti imati veće prinose jer investitori zahtjevaju veći prinos za kompenzaciju povećanog nesustavnog rizika (detaljan opis mehanizma vidjeti u Lehavy i Sloan, 2008). Razlozi raspoznavanja samo ograničenog broja dionica zbog ograničenja u obliku uloženog truda i vremena naspram dobivenog (Barber i Odean, 2008). Iz tih razloga je investitorova pozornost usmjerena najviše na one dionice s kojima je upoznat (Cao i dr. 2011, Tesar i Werner, 1995). Na taj način je važan učinak na trgovanje dionicama s kojima je investitor upoznat i na koje je usmjeren.

Uključivanje volumena *online* pretraživanja u financijsko modeliranje veoma je popularno u posljednjih nekoliko godina. Najčešće primijenjene metodologije uključuju univarijatne ARMA-GARCH modele u koje se uključuje volumen pretraživanja kao prediktorna varijabla, ili pak VAR modeli. Najviše istražena tržišta su američko, britansko, francusko i slična razvijenija tržišta, dok su nešto oskudnije analize usmjerene na tržišta poput hrvatskog. Primjene se usmjeravaju na službeni tržišni indeks. Nadalje, uobičajeno je za volumen internetskog pretraživanja uzeti sam naziv tržišnog indeksa koji se razmatra ili dio naziva samog indeksa (ukoliko se radi o nazivu s više riječi). Većina radova razmatra kratkoročnu dinamiku što ima smisla jer se radi o proučavanju dinamičkih tržišta dionica.

Početne analize koristile su rezultate tada dostupnih *online* rezultata pretraživanja, s obzirom da još nisu bili dostupni dovoljni dugački vremenski nizovi s tražilica poput *Google*. Tako Mondria i dr. (2010) koriste AOL bazu rezultata istraživanja u SAD-u kako bi razvili model predviđanja ponašanja investitora s obzirom na njihovo pretraživanje u svrhu ostvarivanja međunarodne diverzifikacije portfelja. Da i dr. (2010) konstruiraju indeks naziva *FEARS* (engl. prijevod strah investitora) temeljem pretraživanja negativnih i pozitivnih vijesti o dionicama koje razmatraju za ulaganje. Rezultati ovog istraživanja pokazali su kako konstruirani indeks može biti izuzetno koristan u predviđaju prinosa i volatilnosti u kratkom roku. Iako su najčešće primjene u literaturi pronađene za dionička tržišta te službene dioničke indekse, razmatraju se pojedinačne dionice u okviru nekog od modela procjenjivanja kapitalne imovine te utjecaj volumena pretraživanja na likvidnost (Bank i dr. 2011; Takeda i Wakao 2014); modeliranje tečaja uz volumen pretraživanja (Smith 2012), itd.

Radovi koji su više vezani uz ovo istraživanje su sljedeći. Vozlyublennaiia (2014) primjenjuje VAR metodologiju za prinos, rizik i volumen pretraživanja vezan uz DJIA, S&P 500 te NASDAQ američke indekse za razdoblje od siječnja 2004. do prosinca 2012. godine. Grangerovi testovi uzročnosti pokazali su da volumen pretraživanja uzrokuje u tom smislu prinose. Dodatno, pronađena je dvosmjerna uzročnost u modelu, ali se radi o kratkoročnoj povezanosti. Hamid i Heiden (2015) razmatraju DJIA indeks te *Google* volumen pretraživanja (tjedni podaci za razdoblje siječanj 2004. do listopad 2013. godine) vezan uz riječ *dow* koja se odnosi na sam naziv DJIA indeksa. Autori su usmjereni na modeliranje volatilnosti prinosa DJIA indeksa te uspoređuju nekoliko modela prognoziranja rizika unutar i van uzorka. Rezultati analize su ukazali kako u razdobljima velike volatilnosti dolazi do povećanja točnosti prognoza kada se uključi volumen pretraživanja u modele. S metodološke strane se razmatraju VAR, ARMA i HAR (engl. *heterogeneous AR*) modeli za modeliranje rizika (modeliranje volatilnosti temeljem njenih različitih frekvencija, vidjeti Corsi 2009). U okviru VAR modela autori nalaze dvosmjernu uzročnost između korištenih varijabli. Dimpfl i Jank (2015) također razmatraju DJIA indeks, odnosno realiziranu volatilnost tog indeksa za razdoblje od srpnja 2006. do prosinca 2011. godine, te procjenjuju ARMA i VAR modele kako bi usporedili točnost prognozi modela bez i s uključenim indeksom pretraživanja vezanih uz ime DJIA. Glavni nalazi istraživanja su sljedeći. Volumen pretraživanja uzrokuje volatilnost DJIA indeksa u Grangerovom smislu, te dodatno dolazi do točnijeg prognoziranja volatilnosti s uključivanjem volumena *Google* pretraživanja. Stoga su autori preporučili uključiti u modeliranje volumen pretraživanja za svrhe ostvarivanja investitorovih ciljeva. Bijl i dr. (2016) su se usmjerili na mogućnost predviđanja prinosa S&P 500 indeksa (za razdoblje od 2008. do 2013. godine), pri čemu su razmatrali dnevne podatke o pretraživanju pomoću *Google Trends* i dodatno računali pomične bete i prinose indeksa temeljem 52-pomičnih tjednih podataka. Glavni nalazi u ovome radu ukazuju da povećanje volumena pretraživanja vodi negativnim prinosima, tj. gubicima (regresijska analiza). Stoga su autori simulirali investicijske strategije temeljene na prognoziranju prinosa s obzirom na uključivanje volumena pretraživanja. Iako su strategije temeljene uz uključen volumen pretraživanje ostvarivale zarade, uključivanjem transakcijskih troškova takve strategije više nisu bile profitabilne.

Američko tržište je ponovno u pozornosti u Habibah i dr. (2017), gdje se prinosi na S&P 500 indeks (za razdoblje od siječnja 2004. do prosinca 2015. godine, tjedni podaci) modeliraju pomoću volumena *Google* pretraživanja i VIX indeksa (engl. *Investor Fear Gauge Index*), u okviru VAR modela, ali i nelinearnih ARDL (engl. *Autoregressive distributed lags*). Autori u ovome radu nalaze da indeks VIX uzrokuje ne samo prinose, nego i volumen pretraživanja o razmatranome indeksu, čime se preporuča uključivanje ovog indeksa u slične analize. Kim i dr. (2019) su se fokusirali na norveško tržište, pri čemu su razmotrili razdoblje od siječnja 2012.

do siječnja 2017. godine. Varijable koje su autori uključili u regresijske modele jesu (abnormalni) prinosi, volumen trgovanja i volatilnost, te su dodatno uključili volumen pretraživanja kao prediktornu varijablu. Rezultati ove analize ukazali su da ne postoji korelacija između volumena pretraživanja i prinosa, a postoji za slučajevne volatilnosti i volumena trgovanja. U ovome slučaju se preporuča radije koristiti volumene pretraživanja za volatilnost dionica, u odnosu na prinose.

Ako se fokus izvrši na hrvatsko tržište koje se analizira u ovome radu, postoji svega nekolicina radova koji su vezani uz ovo istraživanje. Čižmešija i dr. (2017) prvi je rad vezan uz Zagrebačku burzu u kojem se temeljem pozitivnih, negativnih i neutralnih vijesti s novinskih portala konstruiraju kompozitni indeksi kako bi se temeljem Grangerovog testa uzročnosti ispitao učinak svih triju tipova vijesti na tržišni prinos i volumen trgovanja. Razmatrano razdoblje analize bio je studeni 2002. do travnja 2017. godine. Autori pronalaze statistički značajnu dvosmjernu uzročnost između prinosa na CROBEX i indikatora negativnih vijesti, kao i između volumena trgovanja i indikatora pozitivnih vijesti, kao i to da prinosi uzrokuju optimizam, dok indeks negativnih vijesti uzrokuje stopu rasta volumena trgovanja. Konačno zaključuju temeljem nalaza kako u Hrvatskoj postoji pristranost negativnih vijesti (engl. *negativity bias*). Škrinjarić (2018) razmatra nekoliko varijanti ARMA-GARCH modela za prognoziranje prinosa i rizika na Zagrebačkoj burzi uz uključivanje varijable koja predstavlja prosjek volumena pretraživanja ključnih riječi vezanih uz CROBEX i samu burzu, za razdoblje od siječnja 2004. do rujna 2018. godine. Uključivanje volumena pretraživanja u prognoziranje prinosa i rizika se pokazalo korisnim, jer se smanjila pogreška prognoziranja. Dodatno su simulirane investicijske strategije temeljene na prognozama van uzorka uz uključen volumen pretraživanja i portfelji koji su konstruirani uz takve rezultate su imali veću vrijednost u odnosu na one koji nisu uključivali volumen pretraživanja u analizu, čak i uz uključene transakcijske troškove. Dakle, postoje mogućnosti iskorištavanja ovakvih rezultata u svrhu ostvarivanja investitorovih ciljeva.

Zaključno se može sažeti kako većina postojećih istraživanja razmatra učinke povećanja volumena pretraživanja na prinose i rizike dioničkih indeksa. Pritom se pretpostavlja jednosmjerna uzročnost od volumena pretraživanja prema prinosa i rizicima. U nekoliko slučajeva autori nalaze kako postoji dvosmjerna uzročnost, no to se detaljnije ne analizira, kao i što su većina analiza statičke u smislu kako se cijeli vremenski raspon dostupnih podataka uzima za procjenu pojedinog modela. Stoga se u ovome istraživanju nadopunjuje nedostaci u postojećoj literaturi: razmatrat će se vremenski promjenjiva veza između prinosa, rizika te volumena pretraživanja službenog indeksa Zagrebačke burze.

3. METODOLOGIJA

Metodologija prelijevanja šokova mjereno indeksima prelijevanja (engl. *Spillover index*) razvijena je u Diebold i Yilmaz (2009, 2012) za VAR(p) modele (engl. *Vector AutoRegression*). Za stabilan VAR(p) model od N varijabli zapisan u kompaktnoj formi:

$$Y_t = v + AY_{t-1} + \varepsilon_t, \quad (1)$$

gdje je $Y_t = [y_t \quad y_{t-1} \quad \dots \quad y_{t-p}]'$, $v = [v \quad 0 \quad \dots \quad 0]'$,

$$A = \begin{bmatrix} A_1 & A_2 & \dots & A_{p-1} & A_p \\ I_N & 0 & \dots & 0 & 0 \\ 0 & I_N & & \vdots & \vdots \\ \vdots & & \ddots & \vdots & \vdots \\ 0 & 0 & \dots & I_N & 0 \end{bmatrix} \text{ te je } \varepsilon_t = [\varepsilon_t \quad 0 \quad \dots \quad 0]'$$
, s ε_t vektorom slu-

čajne varijable, $E(\varepsilon_t) = \mathbf{0}$, $E(\varepsilon_t \varepsilon_t') = \Sigma_\varepsilon < \infty$ i za $t \neq s$ $E(\varepsilon_t \varepsilon_s') = 0$. U svrhu procjene funkcija impulsnog odziva i dekompozicije varijance, razmatra se MA(∞) reprezentacija modela (1):

$$Y_t = \mu + \sum_{i=1}^{\infty} A^i \varepsilon_{t-i}, \quad \mu \equiv (I_{Np} - A)^{-1} v, \quad (2)$$

pri čemu se polinomska forma modela (2) definira izrazom:

$$Y_t = \Phi(L)\varepsilon_t, \quad (3)$$

a $\Phi(L)$ je polinom operatora pomaka L , s vrijednostima $\phi_{jk,i}$ koje predstavljaju koeficijente impulsnih odziva u VAR modelu. Kako su slučajne varijable u ε_t korelirane, potrebno je matricu varijanci-kovarijanci ortogonalizirati Choleski dekompozicijom ili se razmatra generalizirana dekompozicija varijance prognostičke pogreške (engl. *generalized forecast error variance decomposition*, GFEVD). U prvome koraku se razmatra pogreška prognoziranja za h koraka unaprijed kao razlika $Y_{t+h} - E(Y_{t+h})$, te se u drugome procjenjuje srednje kvadratno odstupanje (engl. *Mean squared error*) za svaki element u $Y_{t+h} - E(Y_{t+h})$: $E\left(y_{j,t+h} - E(y_{j,t+h})\right)^2$, odnosno varijanca varijable j . Potom se varijanca svake varijable dekomponira na

udjele svih varijabli u VAR modelu, zbog šokova u pojedinačnoj varijabli cijelog modela:

$$\omega_{jk,h} = \frac{\sigma_j^{-1} \sum_{i=0}^{h-1} \left(e_j' \Phi_i \Sigma_\varepsilon e_k \right)^2}{e_j' \Phi_i \Sigma_\varepsilon \Phi_i' e_j}, \quad (4)$$

gdje $\omega_{jk,h}$ predstavlja udio varijance varijable j u h -tom koraku prognoziranja koji je uzrokovan šokom u varijabli k , e_j i e_k predstavljaju j -ti i k -ti vektor redak matrice I_{Np}^{-1} . Sada se temeljem (4) definira indeks prelijevanja u Diebold i Yilmaz (2009, 2012) kao:

$$S = \frac{\sum_{\substack{j,k=1 \\ j \neq k}}^N \omega_{jk,h}}{\sum_{i=0}^{h-1} \sum_{j,k=1}^N \omega_{jk,h}} 100\%, \quad (5)$$

gdje brojnik predstavlja sumu svih udjela varijanci svih varijabli u modelu uzrokovanih šokovima u svim drugim varijablama, a nazivnik ukupnu varijancu prognoziranja. Osim ukupnog indeksa prelijevanja šokova (5), uobičajeno je procijeniti indekse prelijevanja usmjerene iz pojedinačne varijable i prema njoj, odnosno indeksi „od“ i „prema“. Indeks prelijevanja prema jednoj varijabli od svih drugih (engl. „to“ *spillover index*) se računa izrazom

$$S_{j\bullet,h} = \frac{1}{N} \sum_{\substack{k=1 \\ j \neq k}}^N \omega_{jk,h} 100\%, \quad (6)$$

dok se indeks prelijevanja šokova od jedne varijable prema drugima (engl. „from“ *spillover index*) računa izrazom

$$S_{\bullet j,h} = \frac{1}{N} \sum_{\substack{k=1 \\ j \neq k}}^N \omega_{kj,h} 100\%, \quad (7)$$

te se neto indeks prelijevanja šokova (engl. *net spillover index*) definira kao razlika prethodna dva. Dodatno, da bi se uključila dinamika u analizu, dinamički indeksi prelijevanja šokova procjenjuju se temeljem pomičnih prozora procjenjivanja VAR modela. Detaljnije se o ovoj metodologiji može vidjeti u Diebold i Yilmaz (2009,

¹ Brojnik u (4) predstavlja doprinos šokova varijable k varijanci varijable j za h razdoblja, a nazivnik je varijanca prognoziranih vrijednosti varijable j .

2011, 2012), Yilmaz (2009, 2010), Koop i dr. (1996), Pesaran i Shin (1998), Urbina (2013), Lütkepohl (1993, 2006, 2010), Demirer i dr. (2018).

4. EMPIRIJSKI REZULTATI

4.1. Opis podataka

Na *Google trends* (2019) stranicama dostupni su mjesečni podaci o pretraživanjima vezanim uz Hrvatsku od travnja 2004. godine, stoga je prikupljen mjesečni volumen pretraživanja ključne riječi CROBEX od navedenog početnog datuma do siječnja 2019. godine (zadnji dostupni podaci u trenutku pisanja istraživanja). Odabrana je riječ CROBEX kao reprezentativna za *online* pretraživanje, s obzirom da se službeni naziv tržišnog indeksa koristi i u Dimpfl i Jank (2015), Vozlyublennaiia (2014), Da i dr. (2015), Hamed i Heiden (2015), Ding i Hou (2015), Shmidt (2012), itd. Dodatno, u Škrinjarić (2018) su računane korelacije pretraživanja ključnih riječi vezanih uz CROBEX i Zagrebačku burzu, gdje je utvrđena statistički značajna pozitivna korelacija između riječi koje se vežu uz hrvatsko tržište dionica, stoga bi zaključci bili slični za odabir drugih ključnih riječi vezanih uz burzu. Konačno, odabrana je tražilica *Google* kao osnovica za mjerenje pozornosti investitora, s obzirom da je udio pretraživanja pomoću ove tražilice u zadnje tri godine najveći u ukupnom broju pretraživanja pomoću svih dostupnih tražilica (prema dostupnim podacima na Netmarketshare 2019; udio se kreće oko 75% od početka 2016. godine od kada navedena web stranica mjeri tržišne udjele pretraživača). Potom su prikupljeni mjesečni podaci o dnevnim vrijednostima indeksa CROBEX sa službenih stranica Zagrebačke burze (2019) za razdoblje 1. travnja 2004. – 31. siječnja 2019. godine.

Tablica 1.

DESKRIPTIVNA STATISTIKA MJESEČNOG PRINOSA, STANDARDNE
DEVIJACIJE I VOLUMENA PRETRAŽIVANJA CROBEX-a


| Varijabla | Google volumen pretraživanja | Prinos na CROBEX | Standardna devijacija CROBEX-a |
|-----------------------|------------------------------|------------------|--------------------------------|
| Skraćenica | Google | Prinos | SD |
| Prosječna vrijednost | 0.1182 | 0.0001 | 0.0087 |
| Standardna devijacija | 0.1495 | 0.0033 | 0.0067 |
| Minimalna vrijednost | 0.0000 | -0.0155 | 0.0024 |
| Maksimalna vrijednost | 1.0000 | 0.0148 | 0.0578 |

Izvor: izračun autorice

Potom su izračunati dnevni prinosi i temeljem njih izračunati su prosječni mjesečni prinosi i standardne devijacije kao mjere rizika. Za svaki vremenski niz dostupan je 181 podatak, pri čemu je deskriptivna statistika dana u tablici 1, grafički prikazi serija dani su na grafikonu 1, dok su pomične 30-mjesečne korelacije prikazane na grafikonu 2. Ono što se može uočiti na grafikonu 1 jest da se posebno u vrijeme krize da povećava volatilitet prinosa na CROBEX, kao i što je tada povećan volumen pretraživanja same riječi tržišnog indeksa. Slično se uočava u drugim istraživanjima, poput njemačkog tržišnog indeksa DAX u Dimpfl i Jank (2015). Dakle, postoji mogućnost da se pretraživanje o tržišnom indeksu može uključiti u prognoziranje budućih prinosa i/ili rizika istog indeksa. Ako se promotre korelacije na grafikonu 2, u vrijeme krize se uočava povećanje korelacije između *Google* i SD (standardne devijacije), dok se korelacija između rizika i prinosa značajno smanjuje i postaje negativna, što je karakteristika medvjedih tržišta. Sličan zaključak vrijedi na početku 2017. godine kada je kriza vezana uz koncern Agrokor također utjecala na Zagrebačku burzu (detalje vidjeti u Škrinjarić i Orlović 2019, te Škrinjarić 2018). S obzirom na promjenjive korelacije, za očekivati je da će se indeksi prelijevanja šokova mijenjati tijekom vremena, te da statička analiza nije preporučljiva.

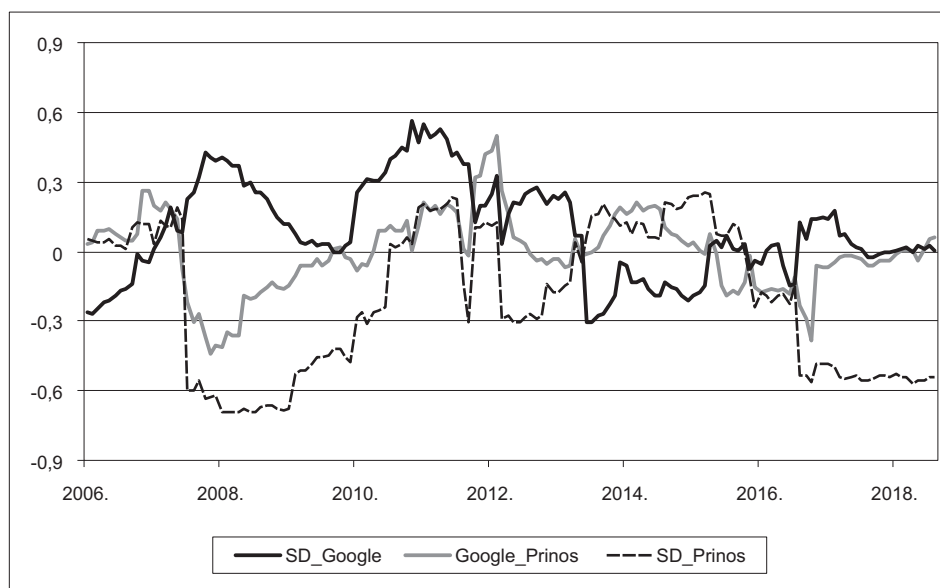
Grafikon 1.

MJESEČNI PRINOS, STANDARDNA DEVIJACIJA I VOLUMEN
PRETRAŽIVANJA CROBEX-a



Izvor: izračun autorice temeljem Zagrebačke burze (2019) i *Google trends* (2019)

Grafikon 2.

30-MJESEČNE POMIČNE KORELACIJE IZMEĐU
RAZMATRANIH VARIJABLI

Izvor: izračun autorice

4.2. Inicijalni rezultati procjena

Najprije su provedeni testovi jediničnih korijena za sve varijable u modelu, pri čemu su rezultati prikazani u tablici 2. Radi se o proširenom Dickey-Fuller testu, gdje se može uočiti da su sve varijable stacionarne na uobičajenim razinama značajnosti. Stoga se u daljnju analizu ulazi s varijablama u razinama. Tablica A1 u dodatku prikazuje optimalan pomak p u VAR modelu prema nekoliko informacijskih kriterija. Kako su rezultati različiti, procjenjivan je VAR model s pomakom sve dok se nisu mogle odbaciti nulte hipoteze multivarijantnih testova o normalnosti, autokorelaciji te heteroskedastičnosti reziduala VAR modela. Za VAR(4) model su testovi ukazivali na ne odbacivanje nulte hipoteze (multivarijantni ARCH test rezultirao je s testnom veličinom 36.55 s pripadajućom p -vrijednošću 0.44 te Breusch-Godfrey LM test s veličinom 13.06 i p -vrijednošću 0.16). Stoga se

ostatak analize temelji na VAR(4) modelu. Proveden je Grangerov test uzročnosti za sve tri varijable u VAR modelu i rezultati ukazuju na odbacivanje nulte hipoteze za sve tri varijable na razini značajnosti od 1%. Dakle, opravdano je razmatrati sve varijable kao endogene u modelu dalje.

Dodatno su procijenjene funkcije impulsnih odziva temeljem procijenjenog VAR(4) modela i prikazane su na grafikonu A1 u dodatku. Ono što se može uočiti jest za slučaj statičkog VAR modela da šokovi u varijabli *Google* vode do negativnih vrijednosti prinosa, odnosno gubitaka, dok se varijabla rizika povećava (povećanje volatilnosti). Ovi nalazi su u skladu s Dimpfl i Jank (2015), kao i što šokovi u SD vode do povećanja *Google* volumena pretraživanja, što je također u skladu s Dimpfl i Jank (2015). Reakcija negativnih prinosa na volumen pretraživanja i obratno je također u skladu s Vozlyublennai (2014). Dakle, radi se o potvrđivanju hipotezi investitorova raspoznavanja i investitorove pozornosti. Širenje informacija o dionicama koje su investitorima prethodno bile nepoznate vodi do smanjenja prinosa zbog cjenovnih pritisaka, kao i što se povećava udio trgovanja malih *noise-trader* investitora koji uzrokuju veću volatilnost na tržištu.

Tablica 2.

REZULTATI TESTOVA JEDINIČNIH KORIJENA ZA VARIJABLE
 U MODELU

| Determinističke varijable u testnoj jednadžbi | <i>Google</i> | Prinos | SD | Kritične razine (1%, 5%, 10%) | | |
|---|---------------|------------|------------|-------------------------------|-------|-------|
| Ništa | -2.5786** | -8.6494*** | -2.4348** | -2.58 | -1.95 | -1.62 |
| Konstanta | -3.2962** | -8.6343*** | -3.2962** | -3.46 | -2.88 | -2.57 |
| Konstanta i trend | -3.4176* | -8.6962*** | -5.4287*** | -3.99 | -3.43 | -3.13 |

Izvor: izračun autorice

Napomena: *, ** i *** označavaju značajnost na 10%, 5% i 1%.

Najprije je za $h = 12$ mjeseci za cijeli vremenski raspon procijenjena tablica prelijevanja šokova, u kojoj su izračunati indeksi „od“, „prema“ te ukupni indeks. Rezultati su prikazani u tablici 3. Odebljana vrijednost je ukupni indeks prelijevanja šokova i iznosi 31.51%. Ostatak rezultata se interpretira kako slijedi. Šokovi u varijabli SD objašnjavaju 80.02% varijance iste varijable, dok se šokovi u varijabla-*ma Google* i prinos preliju u varijablu SD na način da se 8.39%, odnosno 11.59% varijance varijable SD objašnjava šokovima u *Google* i prinosu. Uočava se kako se šokovi u varijabli SD objašnjavanju značajan dio varijance *Google* (preko 42%)

te kako šokovi u varijabli *Google* objašnjavaju veći dio varijance SD u odnosu na varijancu prinosa (8.39% u odnosu na 4.42%). Stoga se zaključuje kako *Google* pretraživanje može više doprinijeti prognoziranju rizika u odnosu na prinos na Zagrebačkoj burzi. Ovi rezultati su u skladu s Andrei i Hasler (2013), Vlastakis i Markellos (2012) te Da i dr. (2011), gdje su autori zaključili kako je *Google* volumen pretraživanja varijabla koja uzrokuje buduću volatilitnost. Kako se radi o tablici čije su vrijednosti procijenjene za cijelo promatrano razdoblje, razmatra se dalje dinamička analiza. Ovi rezultati su u skladu s rezultatima u Škrinjarić (2018), gdje je pronađen statistički značajan učinak pretraživanja ključnih riječi vezanih uz Zagrebačku burzu i indeks CROBEX i na prinos i rizik; te je u Kim i dr. (2019) rezultat analize ukazao na veću moć predviđanja rizika u odnosu na prinose dionica.

Tablica 3.

TABLICA PRELIJEVANJA ŠOKOVA IZMEĐU VARIJABLI
SD, *GOOGLE* I PRINOS

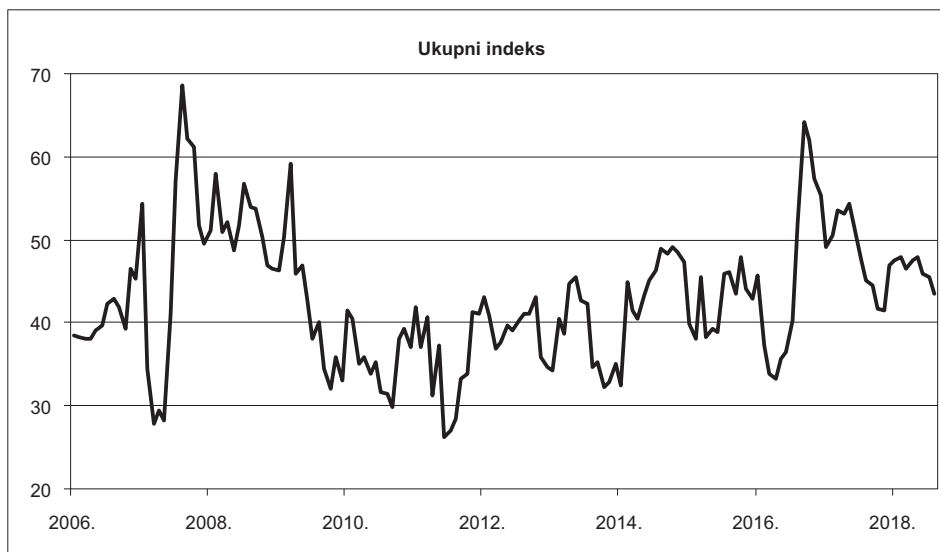
| | SD | Google | Prinos | Od |
|---------------|-----------|---------------|---------------|--------------|
| SD | 80.02 | 8.39 | 11.59 | 6.66 |
| <i>Google</i> | 42.07 | 42.85 | 15.09 | 19.05 |
| Prinos | 12.97 | 4.42 | 82.61 | 5.80 |
| Prema | 18.35 | 4.27 | 8.89 | 31.51 |

Izvor: izračun autorice

Temeljem pomičnih prozora duljine 30 mjeseci procijenjen je ukupni indeks prelijevanja šokova za razmatrane varijable u VAR modelu te je prikazan na grafikonu 3. Time se uključuje dinamika u analizu, kako bi se razmotrilo postoje li značajnije promjene u ukupnome prelijevanju tijekom razmatranog razdoblja koje se ne mogu uočiti u statičkoj analizi. Uočava se da su najveće vrijednosti indeksa u vrijeme financijske krize, kao i u vrijeme krize koncerna Agrokor. U razdoblju kada je tržište stagniralo (nakon oporavka od krize iz 2008. godine) vrijednost indeksa je na nižim razinama, s obzirom na povlačenje investitora s burze te obustavu trgovanja pojedinim dionicama. Povećanje indeksa prelijevanja šokova javlja se tek u 2016. godini, čemu uzrok može biti to što je Zagrebačka burza te godine ušla u vlasništvo Ljubljanske burze, te je kreiran SEE (engl. *South East European*) link kojim je došlo do povezivanja nekoliko dioničkih burzi zemalja Jugoistočne Europe, stoga se povećao volumen trgovanja, kao i pretraživanja o svim tržištima, pa tako i o hrvatskome.

Grafikon 3.

POMIČNI UKUPNI INDEKS PRELIJEVANJA ŠOKOVA,
DULJINA PROZORA = 30 MJESECI



Izvor: izračun autorice

Dalje se detaljnije razmatra kako se šokovi u pojedinoj varijabli prelijevaju u druge varijable, kako bi se ustvrdilo koja varijabla u modelu je neto primatelj a koja neto davatelj šokova, razmatraju se neto pomični indeksi na grafikonu 4: panel (a), te pojedinačni parovi neto šokova u panelu (b). Na panelu (a) se može uočiti da je u pred krizno razdoblje neto davatelj šokova bio *Google* indeks te u jeku krize (početak 2008. godine) varijabla SD postala neto davatelj i tek u 2009. godini prinos postaje neto davatelj šokova u sustavu. Ovi nalazi su također u skladu s teorijom, da povećanje pozornosti investitora vodi povećanju rizika i smanjenju prinosa dionica. S obzirom na izmjenjivanje razdoblje kada pojedinačna varijabla postaje neto davatelj ili primatelj šokova, može se zaključiti da prethodne analize gdje se isključivo pretpostavlja jednosmjerna veza između razmatranih varijabli ili se pak razmatra statički oblik VAR modela, da takve analize mogu upućivati na krive zaključke. Ovakvi rezultati su u skladu s Da i dr. (2011).

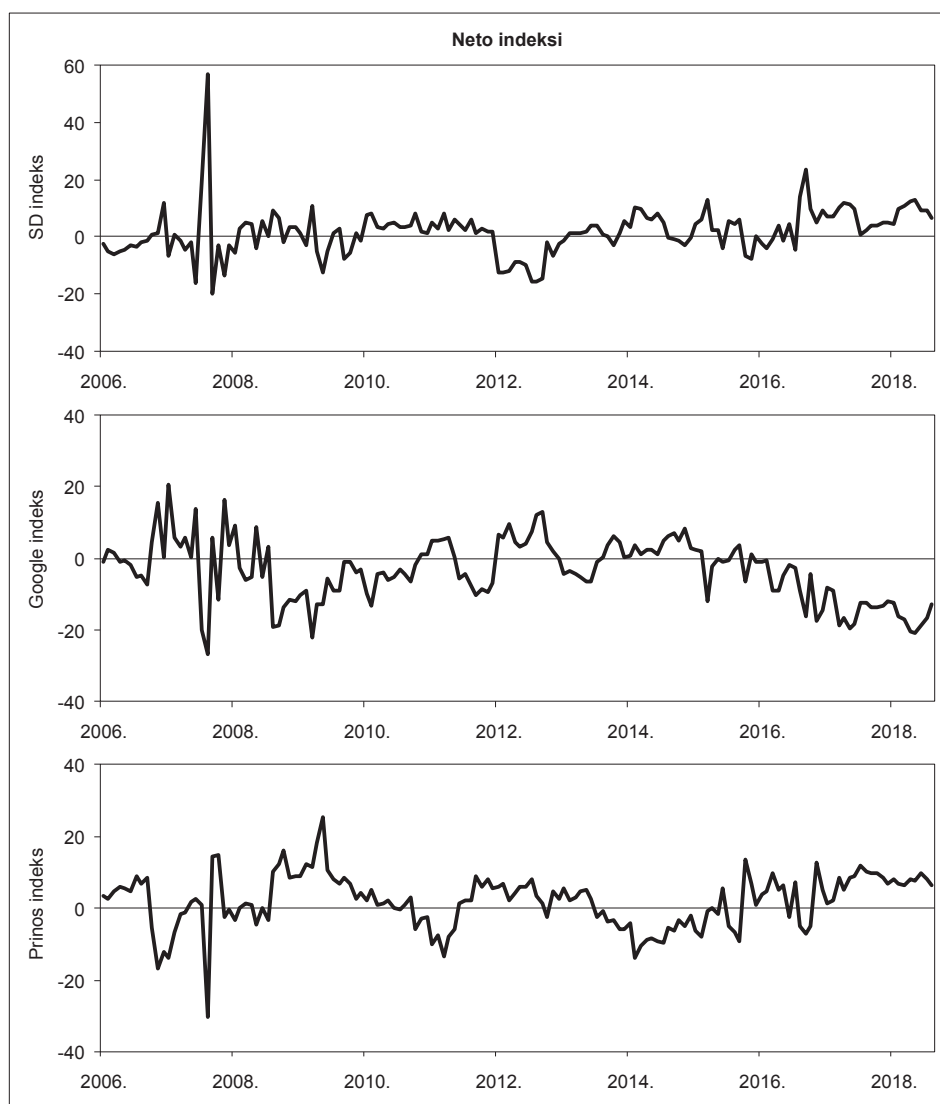
Nadalje, u razdoblju kada su trgovanje na burzi kao i vrijednost indeksa CRO-BEX stagnerali (2010. do početka 2017. godine) uočava se manja volatilitnost svih neto indeksa. Kriza koncerna Agrokor početkom 2017. godine je uočljiva u skokovima tih indeksa. Panel (b) prikazuje neto indekse prelijevanja šokova za svaki par varijabli u

modelu. U jeku krize je neto davatelj šokova bila varijabla SD i za prinos i *Google*. Nadalje, uočava se da je prelijevanje šokova iz *Google* u rizike bilo u većoj mjeri u odnosu na prinose, što potvrđuje prethodni zaključak kako je *Google* pretraživanje korisnije za predviđanje rizika u odnosu na prinose na Zagrebačkoj burzi.


Grafikon 4.

POMIČNI NETO INDEKSI PRELIJEVANJA ŠOKOVA (A) TE PAROVI INDEKSA PRELIJEVANJA ŠOKOVA (B), DULJINA PROZORA = 30 MJESECI

(A)



(B)




Izvor: izračun autorice

4.3. Provjera robusnosti rezultata

Konačno, provedena je provjera robusnosti rezultata kako bi se ispitala pouzdanost prethodnih nalaza. U tu svrhu slijedi se postupak u Diebold i Yilmaz (2011), gdje se preporuča mijenjati duljinu pomičnih prozora kako bi se usporedile vrijednosti pomičnih indeksa prelijevanja šokova. Ideja je da bi vrijednosti svih indeksa bez obzira na vrijednost duljine pomičnih prozora trebala slijediti sličnu dinamiku, jedino se u vrijednosti razina mogu razlikovati. Stoga se na grafikonu 5 uspoređuju indeksi za duljinu od 25, 30, 35 i 40 mjeseci, gdje se može uočiti da tijekom vremena sva četiri indeksa slijede sličnu dinamiku, s nešto većim odstupanjima indeksa za 25 mjeseci u srednjem dijelu promatranog razdoblja analize.

Grafikon 5.

USPOREDBA UKUPNIH INDEKSA PRELIJEVANJA S OBZIROM NA RAZLIČITU DULJINU POMIČNIH PROZORA




Izvor: izračun autorice

Daljnja robusnost je provjerena na način da su se neto indeksi prelijevanja usporedili s ishodima pomičnih Grangerovih testova unutar VAR modela. Kada je neto indeks prelijevanja za neku varijablu pozitivan (varijabla je neto davatelj šokova u modelu), ishod Grangerova testa bi trebao to potvrditi na način da p -vrijednost Grangerova testa ukazuje na odbacivanje nulte hipoteze uzročnosti. U tu svrhu su na grafikonu 6 uspoređeni neto indeksi s odgovarajućim pomičnim p -vrijednostima koje su računane temeljem pomičnih prozora u istoj duljini, od 30 mjeseci. Ono što se može zaključiti jest da kada su vrijednosti pojedinačnih neto indeksa negativne (varijabla je neto primatelj šokova), p -vrijednosti su velike što potvrđuje robusnost rezultata. Naime, tada varijabla u Grangerovom smislu ne uzrokuje druge varijable. Ovdje se dodatno vidi da je bolje razmatrati dinamiku tijekom vremena, s obzirom da dolazi do promjena p -vrijednosti i ishoda testova za sve varijable u modelu.

Grafikon 6.

USPOREDBA NETO INDEKSA PRELIJEVANJA ŠOKOVA (LIJEVA OS, ISCRTKANA LINIJA) S POMIČNIM GRANGEROVIM TESTOVIMA (DESNA OS, PUNA LINIJA)



Izvor: izračun autorice

Posljednja provjera robusnosti izvršena je na način da je umjesto varijance kao mjera rizika razmatrana realizirana volatilnost (engl. *realized volatility*),

izračunata prema formuli: $RV_{\tau} = \sqrt{\sum_{t=1}^{\tau} r_t^2}$ (vidjeti Andersen i Bollerslev 1986,

Barndorff-Nielsen i Shepard 2002), gdje je duljina pomičnog prozora ponovno odabrana kao 30 mjeseci, za usporedivost s prethodnim rezultatima. Ponovno je procijenjen VAR model, pri čemu je optimalan broj pomaka u ovome slučaju bio 4, te su testovi normalnosti, autokorelacije i heteroskedastičnosti ukazali na ne odbacivanje nultih hipoteza svih testova. Tablica prelijevanja šokova za slučaj korištenja RV (realizirane volatilnosti) prikazana je u tablici 4. Kada se vrijednosti u tablici 4 usporede s vrijednostima u tablici 3, vrijednosti su veoma slične i vrijede jednaki zaključci kao kod tablice 3. Konačno je uspoređen indeks ukupnog prelijevanja s obzirom na pomične prozore za RV kao mjeru rizika s varijancom na grafikonu 7. Uočava se da se oba indeksa kreću veoma slično. Korelacija za oba niza iznosi 0.94. Indeks prelijevanja za SD varijablu je nešto više volatilan (veća mu je izračunata standardna devijacija, 8.71 u odnosu na 8.04), što znači da za slučaj SD su varijable u sustavu više osjetljive na prelijevanje šokova, u odnosu na RV.

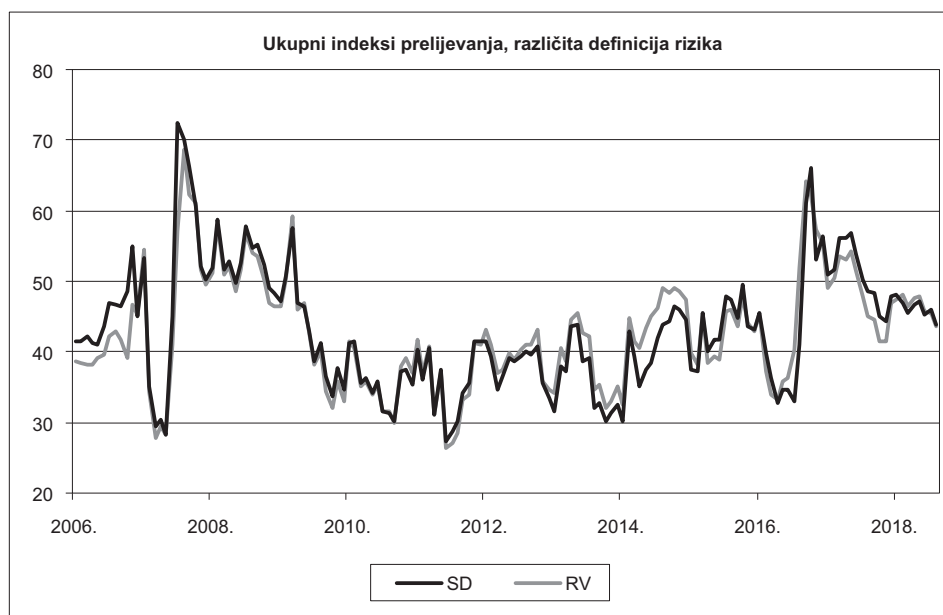
Tablica 4.

TABLICA PRELIJEVANJA ŠOKOVA IZMEĐU VARIJABLI
 RV, *GOOGLE* I PRINOS

| | RV | <i>Google</i> | Prinos | Od |
|---------------|-----------|---------------|---------------|--------------|
| RV | 81.34 | 8.73 | 9.94 | 6.22 |
| <i>Google</i> | 40.05 | 44.68 | 15.28 | 18.44 |
| Prinos | 10.63 | 4.60 | 84.77 | 5.08 |
| Prema | 16.89 | 4.44 | 8.40 | 29.74 |

Izvor: izračun autorice

Grafikon 7.

PROVJERA ROBUSNOSTI REZULTATA USPOREDBOM INDEKSA
PRELIJEVANJA ZA SD I RV

Izvor: izračun autorice

4.4. Diskusija

S obzirom na dobivene rezultate, može se iznijeti nekoliko zaključaka. Najprije, uočava se da je potrebno u analizu problema u ovome istraživanju razmatrati uzročnost u oba smjera, s obzirom da je nerealno pretpostaviti jednosmjernu vezu od *online* pretraživanja prema riziku i/ili prinosu dionica. Ovi nalazi su u skladu s teorijom Grossmana i Stiglitz (1980) da veća informiranost investitora vodi boljoj efikasnosti tržišta dionica, ali i s tvrdnjama u Da i dr. (2011) gdje povećana pozornost investitora vodi većoj nestabilnosti na tržištu. Nalazi su u skladu s teorijom u Merton (1987) te Da i dr. (2011), što znači da korištenje *Google* volumena pretraživanja u modeliranju prinosa i rizika može objasniti ponašanje manjih investitora na Zagrebačkoj burzi. Nadalje, potrebno je uključiti i dinamiku, jer se

radi o promjenjivim vezama tijekom vremena, posebice jer se radi o dinamičkim tržištima poput dioničkog. Ukupni indeks prelijevanja šokova je ukazao na povećanje prelijevanja šokova u varijablama u sustavu u vrijeme financijskih kriza ili specifičnih kriza (poput krize vezane uz koncern Agrokor). Dakle, za očekivati je da dolazi do promjena u karakteristikama međuovisnosti razmatranih varijabli, barem u vrijeme kada se očekuju medvjeda tržišta. Kako dolazi do povećanja prelijevanja šokova u vrijeme kriza, volumen *online* pretraživanja može pomoći u prognoziranju prinosa ili rizika. Na hrvatskom dioničkom tržištu dolazi do većih prelijevanja šokova iz volumena *online* pretraživanja u rizike u odnosu na prinose, stoga se investitorima može preporučiti da u modeliranju i prognoziranju rizika uključe i tu varijablu.

Kako se u istraživanju razmatrao VAR modeli koji se koristi za kratkoročna modeliranja, rezultati dobiveni u empirijskom dijelu analize vrijede u kratkome roku, što je u skladu s prethodnom literaturom (Vozlyublennai 2014). Zato se ovakve analize i buduće primjene preporučaju za kratkoročno prognoziranje prinosa, te posebice rizika na Zagrebačkoj burzi. Dodatno, radi se o metodologiji koju je moguće relativno brzo i lako primijeniti u svrhe gotovo svakodnevne upotrebe u menadžmentu portfelja. Buduće analize trebale bi ispitati mogućnosti prognoziiranja razmatranih varijabli u ovome istraživanju u okviru ovakvih multivarijatnih modela te vidjeti mogu li se ostvariti profitabilne investicijske strategije (i uz uključene transakcijske troškove).

5. ZAKLJUČAK

Sve veći izazovi u financijskom modeliranju potaknuli su na razvoj interesa za razmatranjem volumena *online* pretraživanja kao mjerom investitorove pozornosti za određenim tržištem i zbivanjima na njemu. Unatoč ubrzanom povećanju broja literature koja analizira probleme koji se razmatraju u ovome radu, postoji još mnogo prostora za daljnja istraživanja. Naime, u ovome radu rezultati su ukazali da nije dovoljno pretpostaviti uzročnost samo u smjeru od volumena pretraživanja prema prinosu i/ili riziku dioničkog tržišta kako se to najčešće radi u literaturi. Stoga se za buduća istraživanja preporuča razmotriti povratnu povezanost, a dodatno i uključiti i vremensku promjenjivost te povezanosti. Konačno, analize mogu razmotriti i asimetričnosti u toj povezanosti.

Neki od nedostataka ovog istraživanja očituju se u frekvenciji korištenih podataka jer za hrvatske podatke u trenutku pisanja ovog istraživanja nisu bili dostupni dnevni podaci o volumenu pretraživanja, što bi zasigurno bilo korisnije potencijalnome investitoru. Dodatno, razmatrao se odabrani vremenski raspon

podataka s obzirom na dostupnost same varijable volumena pretraživanja, čiji su podaci dostupni od 2004. godine. Također, kao potencijalno ograničenje javlja se i činjenica kako se broj korisnika Interneta u Hrvatskoj u promatranom razdoblju kontinuirano povećavao. To znači da to povećanje može uzrokovati inteziviranje *Google* pretraga termina „CROBEX“. Prema Eurostatovim dostupnim podacima od 2007. godine naovamo, broj korisnika Interneta koji su ga koristili u posljednja 3 mjeseca se povećao s 38% na 79% populacije, dok se udio stanovništva koji koriste Internet barem jednom tjedno povećao s 32% na 77% (Europska Komisija – Eurostat 2020).

Buduća istraživanja se trebaju usmjeriti na mogućnost pronalaska tjednih podataka kako bi se dobile još potpunije informacije o promatranome problemu. Nadalje, analize se mogu usmjeriti i na pojedinačne indekse ili skupine dionica u ovisnosti o specifičnim interesima i ciljevima investitora. Konačno, kako se međuovisnost između volumena pretraživanja, prinosa i rizika potvrdila na Zagrebačkoj burzi, buduća istraživanja usmjerena na prognoziranja trebala bi uvažiti ove nalaze. Na taj način se modeliranje i prognoziranje u svrhu ostvarivanja investitorovih ciljeva na dioničkom tržištu treba usmjeriti i na pronalazak adekvatnih modela u koje će se ugraditi dobiveni rezultati.

LITERATURA

1. Aaltonen, J., Östermark, R. (1997). A rolling test of granger causality between the Finnish and Japanese security markets. *Omega*, Vol. 25, No. 6, str. 635-642.
2. Alfarano, S., Lux, T. (2007). A noise trader model as a generator of apparent financial power laws and long memory. *Macroeconomic Dynamics*, Vol. 11 (Supplement S1), str. 80-101
3. Andersen, T. G. (2008). Realized Volatility. U: *The New Palgrave Dictionary of Economics*. Palgrave Macmillan, London.
4. Andersen, T. G., Bollerslev, T. (1998). Answering the sceptics: yes standard volatility models do provide accurate forecasts, *International Economic Review*, Vol. 39, No. 4, str. 885-905.
5. Andrei, D., Hasler, M. (2015). Investor attention and stock market volatility. *The Review of Financial Studies*, Vol. 28, No. 1, str. 33-72.
6. Antonakakis, N., Andre, C., Gupta, R. (2016). Dynamic Spillovers in the United States: Stock Market, Housing, Uncertainty, and the Macroeconomy. *Southern Economic Journal*, Vol. 83, No. 2, str. 609-624.

7. Antonakakis, N., Breitenlechner, M., Scharler, J. (2015). Business cycle and financial cycle spillovers in the G7 countries. *The Quarterly Review of Economics and Finance*, Vol. 58, str. 154-162.
8. Astakis, N., Zimmerman, K. F. (2009). *Google* Econometrics and Unemployment Forecasting. IZA Discussion Paper Series, Discussion Paper No. 4201.
9. Bangwayo-Skeete, P. F., Skeete, R. W. (2015). Can *Google* data improve the forecasting performance of tourist arrivals? Mixed-data sampling approach, *Tourism Management*, Vol. 46, No. C, str. 454-464.
10. Bank, M., Larch, M., Peter, G. (2011). *Google* search volume and its influence on liquidity and returns of German stocks, *Financial Markets and Portfolio Management*, Vol. 25, No. 3, str. 239-264.
11. Barber, B., Odean, T. (2008). All that Glitters: The Effect of Attention and News on the Buying Behavior of Individual and Institutional Investors. *Review of Financial Studies*, Vol. 21, No. 2, str. 785-818.
12. Barber, B. M., Terrance O., Zhu, N. (2009). Do Retail Trades Move Markets? *Review of Financial Studies*, Vol. 22, No. 1, str. 151-186.
13. Barndorff-Nielsen, O. E., Shephard, N. (2002). Econometric analysis of realised volatility and its use in estimating stochastic volatility models, *Journal of the Royal Statistical Society, Series B.*, Vol. 64, No. 2, str. 253-280.
14. Barreira, N., Godinho, P., Melo, P. (2013). Nowcasting unemployment rate and new car sales in south-western Europe with *Google* Trends, *Netnomics*, Vol. 14, No. 3, str. 129-165.
15. Bijl, L., Kringhaug, G., Molnar, P., Sandvik, E. (2016). *Google* searches and stock returns. *International Review of Financial Analysis*, Vol. 45, str. 150-156.
16. Bortoli, C., Combes, S. (2015). Contribution from *Google* Trends for forecasting the short-term economic outlook in France: limited avenues. Institut national de la statistique et des études économiques. Dostupno na <https://www.insee.fr/en/statistiques/1408911?sommaire=1408916> [pristupljeno 10. travnja 2019.]
17. Brooks, C. (1998). Predicting stock index volatility: can market volume help?, *Journal of Forecasting*, Vol. 17, No. 1, str. 59-80.
18. Bulut, L. (2015). *Google* Trends and Forecasting Performance of Exchange Rate Models, No 1505, IPEK Working Papers from Ipek University, Department of Economics.
19. Cao, H., Han, B., Hirshleifer, D., Zhang, H. (2011). Fear of the Unknown: Familiarity and Economic Decisions. *Review of Finance*, Vol. 15, No. 1, str. 173-206.
20. Corsi, F. (2009). A simple approximate long-memory model of realized volatility. *Journal of Financial Econometrics*, Vol. 7, No. 2, str. 174-196.

21. Čižmešija, M., Sorić, P. i Matošec, M. (2017) Zagreb Stock Exchange And The (A)Symmetric Effects Of News, Proceedings of the 14th International Symposium on Operational Research, Bled, Slovenia / Zadnik Stirn, L.; Kljaič Borštinar, M.; Žerovnik, J; Drobne, S. (ur.). Ljubljana: Slovenian Society Informatika, Section for Operational Research, 2017. str. 403-408.
22. Da, Z., Engelberg, J. , Gao, P. (2011). In search of attention, The Journal of Finance, Vol. 66, No. 5, str. 1461-99.
23. Da, Z., Engelberg, J., Gao, P. (2010). The Sum of All Fears: Investor Sentiment and Asset Prices, SSRN eLibrary.
24. Da, Z., Engelberg, J., Gao, P. (2015). The Sum of All FEARS Investor Sentiment and Asset Prices, The Review of Financial Studies, Vol. 28, No. 1, str. 1-32.
25. D'Amuri, F., Marcucci, J. (2017). The predictive power of *Google* searches in forecasting us unemployment. International Journal of Forecasting, Vol. 33, No. 4, str. 801-816.
26. Demirer, M., Gokcen U., Yilmaz, K. (2018). Financial Sector Volatility Connectedness and Equity Returns. Koc University-TUSIAD Economic Research Forum, Working Paper No. 1803.
27. Dergiades, T., Mavragani, E., Pan, B. (2018). *Google* trends and tourists' arrivals: Emerging biases and proposed corrections. Tourism Management, Vol. 66, str. 108-120.
28. Diebold, F. X., Yilmaz, K. (2009). Measuring Financial Asset Return and Volatility Spillovers with Application to Global Equity Markets. The Economic Journal, Vol. 119, No. 534, str. 158-171.
29. Diebold, F. X., Yilmaz, K. (2011). Equity Market Spillovers in the Americas," in R. Alfaro (ed.) Financial Stability, Monetary Policy, and Central Banking. Santiago: Bank of Chile Central Banking Series, Vol. 15, str. 199-214.
30. Diebold, F. X., Yilmaz, K. (2012). Better to Give than to Receive: Predictive Directional Measurement of Volatility Spillovers, International Journal of Forecasting Vol. 28, No. 1, str. 57-66.
31. Dimpfl, T., Jank, S. (2015). Can Internet Search Queries Help to Predict Stock Market Volatility?. European Financial Management, Vol. 22, No. 2, str. 171-192.
32. Ding, R., Hou, W. (2015). Retail investor attention and stock liquidity, Journal of International Financial Markets, Institutions and Money, Vol. 37, No. C, str. 12-26
33. Donaldson, R. G., Kamstra, M. J. (2005). Volatility forecasts, trading volume, and the arch versus option-implied volatility trade-off. Journal of Financial Research, Vol. 28, No. 4, str. 519-538.

34. Europska Komisija (2020). Eurostat. Dostupno na <https://ec.europa.eu/eurostat/data/database> [pristupljeno 18. siječnja 2020.]
35. Fama, E. F. (1965). Random Walks In Stock Market Prices, *Financial Analysts Journal*, Vol. 21, No. 5, str. 55-59.
36. Fama, E. F. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work. *The Journal of Finance*, Vol. 25, No. 2, str. 383-417.
37. Goel, S., Hofman, J. M., Lahaie, S., Pennock, D. M., Watts, D. J. (2010). Predicting Consumer Behavior with Web Search. *Proceedings of the National Academy of Sciences*, Vol. 107, No. 41, str. 17486-17490.
38. Goel, S., Hofman, J. M., Lahaie, S., Pennock, D. M., Watts, D. J. (2010). Predicting consumer behavior with Web search. *Proceedings of the National Academy of Sciences of the United States of America*, Vol. 107, str. 17486-17490.
39. *Google trends* (2019). Dostupno na <http://trends.Google.com/trends/> [pristupljeno 10. travnja 2019.]
40. Habibah, U., Rajput, S., Sadhwani, R. (2017). Stock market return predictability: *Google* pessimistic sentiments versus fear gauge. *Cogent Economics & Finance*, Vol. 5, No. 1, str. 1-15.
41. Hamid, A., Heiden, M. (2015). Forecasting volatility with empirical similarity and *Google Trends*, *Journal of Economic Behavior & Organization*, Vol. 117, str. 62-81.
42. Havranek, T., Zeinalov, A. (2018). Forecasting Tourist Arrivals: *Google Trends* Meets Mixed Frequency Data. Munich Personal RePEc Archive, MPRA paper No. 90203
43. Jun, S-P., Yoo, H. S., Choi, S. (2018). Ten years of research change using *Google Trends*: From the perspective of big data utilizations and applications. *Technological Forecasting & Social Change*, Vol. 130, str. 69-87.
44. Kim, N., Lučvijanska, K., Molnar, P., Villa, R. (2019). *Google* searches and stock market activity: Evidence from Norway. *Finance Research Letters*, Vol. 28, str. 208-220.
45. Koop, G., Pesaran, H. M., Potter, S. (1996). Impulse response analysis in nonlinear multivariate models. *Journal of Econometrics*, Vol. 74, No. 1, str. 119-147.
46. Lehavy, R., Sloan, R. G. (2008). Investor recognition and stock returns. *The Review of Accounting Studies*, Vol. 13, No. 2, str. 327-361.
47. Lintner, J. (1965). The valuation of risk assets and the selection of risky investments in stock portfolios and capital budgets, *Review of Economics and Statistics*, Vol. 47, No. 1, str. 13-37.

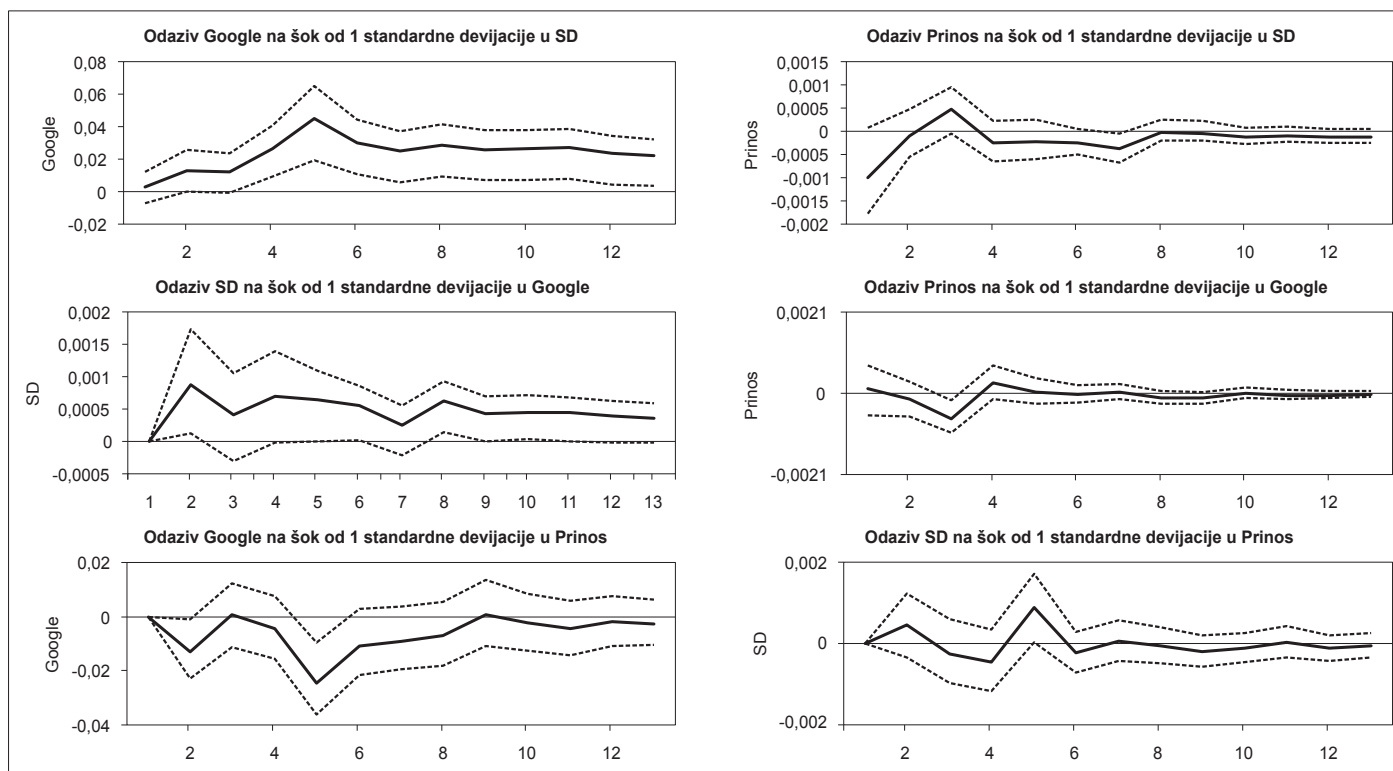
48. Lui, C., Metaxas, P. T., Mustafaraj, E. (2011). On the predictability of the US elections through search volume activity. In: Proceedings of the IADIS International Conference on e-Society. Citeseer.
49. Lütkepohl, H. (2010). Vector Autoregressive Models. Economics Working Paper ECO 2011/30, European University Institute.
50. Lütkepohl, H. (1993). Introduction to multiple time series analysis. Springer-Verlag.
51. Lütkepohl, H. (2006). New Introduction to Multiple Time Series Analysis, Berlin: Springer.
52. Lux, T., Marchesi, M. (1999). Scaling and criticality in a stochastic multi-agent model of a financial market. *Nature*, Vol. 397, str. 498-500.
53. Merton, R.C. (1987). A simple model of capital market equilibrium with incomplete information, *The Journal of Finance*, Vol. 42, No. 3, str. 483-510.
54. Mondria, J., Wu, T., Zhang, Y. (2010). The determinants of international investment and attention allocation: using internet search query data, *Journal of International Economics*, Vol. 82, No. 1, str. 85-95.
55. Mossin, J. (1966). Equilibrium in a Capital Asset Market, *Econometrica*, Vol. 34, No. 4, str. 768-783.
56. Naccarato, A., Falorsi, S., Loriga, S., Pierini, A. (2018). Combining official and *Google Trends* data to forecast the Italian youth unemployment rate, *Technological Forecasting and Social Change*, Vol. 130, No. C, str. 114-122.
57. Netmarketshare (2019). Dostupno na <https://netmarketshare.com> [pristupljeno 10. travnja 2019.]
58. Önder, I. (2017). Forecasting tourism demand with *Google trends*: Accuracy comparison of countries versus cities. *International Journal of Tourism Research*, Vol. 19, No. 6, str. 648-660.
59. Pesaran, H. M., Shin, Y. (1998). Generalized impulse response analysis in linear multivariate models. *Economics Letters*, Vol. 58, No. 1, str. 17-29.
60. Schmidt, D. (2012). Investors' Attention and Stock Covariation Evidence From *Google Sport Searches*. INSEAD Working Paper.
61. Sharpe, W. F. (1994). The Sharpe Ratio, *Journal of Portfolio Management*, Vol. 21, No. 1, str. 49-58.
62. Sims, C. A. (2003). Implications of rational inattention. *Journal of Monetary Economics*, Vol. 50, No. 3, str. 665-690.
63. Smith, G. P. (2012). *Google* Internet Search Activity and Volatility Prediction in the Market for Foreign Currency, *Finance Research Letters*, Vol. 9, No. 2, str. 103-110.

64. Smith, K. L., Brocato, J. and Rogers, J. E. (1993). Regularities in the data between major equity markets: evidence from Granger causality tests. *Applied Financial Economics*, Vol. 3, No. 1, str. 55-60.
65. Škrinjarić, T. (2018). Mogu li *Google* trend podaci poboljšati prognoziranje prinosa na Zagrebačkoj burzi?. Zbornik radova Ekonomskog fakulteta Sveučilišta u Mostaru, Vol. 24, str. 58-76.
66. Škrinjarić, T., Orlović, Z. (2019). Effects of economic and political events on stock returns: event study of Agrokor case in Croatia. *Croatian economic survey*, Vol. 21, No. 1, str. 47-86.
67. Takada, F., Wakao, T. (2014). *Google* search intensity and its relationship with returns and trading volume of Japanese stocks. *Pacific-Basin Finance Journal*, Vol. 27, str. 1-18.
68. Tesar, L., Werner, I. (1995). Home Bias and High Turnover. *Journal of International Money and Finance*, Vol. 14, No. 4, str. 467-492.
69. Tkacz, G. (2013). Predicting Recessions in Real-Time: Mining *Google* Trends and Electronic Payments Data for Clues, C. D. Howe Institute Commentary, C.D. Howe Institute, Issue 387.
70. Treynor, J. L. (1961). Market Value, Time, and Risk, dostupno na: <http://dx.doi.org/10.2139/ssrn.2600356> [pristupljeno 18. siječnja 2019.]
71. Treynor, J. L. (1962). Toward a Theory of Market Value of Risky Assets, dostupno na: <https://ssrn.com/abstract=628187>, [pristupljeno 18. siječnja 2019.]
72. Urbina, J. (2013). Financial Spillovers Across Countries: Measuring shock transmissions. MPRA Working paper.
73. Vlastakis, N., Markellos, R. N. (2012). Information demand and stock market volatility. *Journal of Banking & Finance*, Vol. 36, No. 6, str. 1808-1821.
74. Vosen, S., Schmidt, T. (2011). Forecasting Private Consumption: Survey Based Indicators vs. *Google* Trends. *Journal of Forecasting*, Vol. 30, No. 6, str. 565-578.
75. Vozlyublennaiia, N. (2014). Investor attention, index performance, and return predictability. *Journal of Banking & Finance*, Vol. 41, No. C, str. 17-35.
76. Woo, J., Owen, A. L. (2019). Forecasting private consumption with *Google* Trends data. *Journal of Forecasting*, Vol. 38, No. 2, str. 81-9.
77. Yilmaz, K. (2010). Return and Volatility Spillovers among the East Asian Equity Markets, *Journal of Asian Economics*, Vol. 21, No. 3, str. 304-313.
78. Yilmaz, K., (2009). International Business Cycle Spillovers, Koç University-TUSIAD Economic Research Forum Working Papers 0903, Koc University-TUSIAD Economic Research Forum.
79. Zagrebačka burza (2019). Dostupno na <http://www.zse.hr> [pristupljeno 10. travnja 2019.]

DODATAK

Grafikon A1.

FUNKCIJE IMPULSNOG ODZIVA ZA VAR (4) MODEL



Izvor: izračun autorice

Napomena: iscrtane linije predstavljaju intervale pouzdanosti na razini od 95%

Tablica A1.

OPTIMALAN POMAK *P* VAR MODELA PREMA ODABRANIM
KRITERIJIMA

| Kriterij | Akaike | Hannan-Quinn | Schwartzov | FPE |
|----------|--------|--------------|------------|-----|
| Pomak | 11 | 4 | 1 | 11 |

Izvor: izračun autorice

Napomena: FPE označava prognostičku grešku (engl. *Forecast Prediction Error*)

RETURN, RISK AND MARKET INDEKS ONLINE VOLUME SEARCH
INTERDEPENDENCE: SHOCK SPILLOVER APPROACH ON ZAGREB
STOCK EXCHANGE

Summary

This research examines the time-varying interdependence and shock spillovers between the return and risk of the official Zagreb Stock Exchange index and the online volume search on the *Google* search engine. The aim is to examine how investors' attention measured by the online volume search can be used in modelling of the return and/or risks of the official stock market index. However, the methodology allows for a feedback relationship from the return and risk series to the volume search variable. Based on monthly data for the period from April 2004 to January 2019, results indicate that a time-varying interdependence is found for all three variables in the model. Moreover, spillover shocks are greater in the financial crisis and the crisis of Agrokor concern (in the spring of 2017). The contribution of this research is found in using a relatively new methodology of spillover index within the vector autoregression model in applying this methodology within the finance topics examined in the literature. Based on the results in the paper, guidelines are given to potential investors for future applications.

Key words: investors' attention, *Google* search volume, VAR, stock returns, shock spillovers