UTJECAJ AMERIČKIH I EUROPSKIH INDEKSA TRŽIŠTA KAPITALA NA CROBEX INDEKS

Konjušak, Nikola

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:124:885397

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

SVEUČILIŠTE U SPLITU

EKONOMSKI FAKULTET

DIPLOMSKI RAD

UTJECAJ AMERIČKIH I EUROPSKIH INDEKSA TRŽIŠTA KAPITALA NA CROBEX INDEKS

Mentorica:

prof. dr. sc. Zdravka Aljinović

Student:

Nikola Konjušak

Broj indeksa: 2151448

Split, lipanj 2018.

SADRŽAJ:

1. UVOD 3
1.1. Problem istraživanja 3
1.2. Predmet istraživanja 5
1.3. Svrha i ciljevi istraživanja 6
1.4. Istraživačka hipoteza 7
1.4.1. Temeljna hipoteza 7
1.4.2. Pomoćne hipoteze 7
1.5. Metode istraživanja 7
1.6. Doprinos istraživanja 8
1.7. Struktura rada 8
2. PREGLED LITERATURE 10
3. TRŽIŠTA KAPITALA 15
3.1. Američko tržište kapitala 15
3.2. Europsko tržište kapitala 18
3.3. Hrvatsko tržište kapitala 21
4. EMPIRIJSKA ANALIZA 26
4.1. Podaci 26
4.2. Empirijski modeli 40
5. REZULTATI ISTRAŽIVANJA 45
6. ZAKLJUČAK 60

7. LITERATURA 62

8. POPIS GRAFIČKIH PRIKAZA 66

9. SAŽETAK 68

10. SAŽETAK NA ENGLESKOM JEZIKU 69

1. UVOD

1.1. Problem istraživanja

Paralelno s razvojem međunarodne trgovine u posljednjim desetljećima, dolazi i do globalizacije svjetskog financijskog sustava. Moderne tehnologije omogućavaju jednostavan pristup različitim financijskim tržištima što doprinosi fleksibilnosti kapitalnih tijekova. Slijedom navedenog, međunarodna financijska tržišta sve više nalikuju savršenim tržištima, iz čega proizlazi sve veća međusobna povezanost tržišnih kretanja.

Međuovisnost razvijenih i nerazvijenih tržišta kapitala ispitivali su mnogi autori. Primjerice, Friedman i Shachmurove (1997) proučavaju međuovisnosti vodećih europskih tržišta kapitala, a Tomić, Sesar i Džaja (2014) opisuju utjecaj vodećeg američkog Dow Jones Industrial Average (DJIA) indeksa na europsko tržište kapitala. John Wei et al.(1995) proučavaju utjecaj razvijenih tržišta na tržišta u razvoju, dok Białkowski, Bohl, i Serwa (2006), s druge strane, odbacuju hipotezu o postojanju snažnog utjecaja američkog financijskog tržišta na ostala financijska tržišta.

Zainteresirani spomenutom problematikom,Morana i Beltratti (2008) promatraju mjesečne promjene na dioničkim tržištima u SAD-u, Ujedinjenom Kraljevstvu, Njemačkoj i Japanu u razdoblju od 1974. do 2004. Predstavljaju teorijski okvir prema kojemu veća međunarodna integracija vodi do veće povezanosti cijena, povrata, volatilnosti i korelacije na tržištima kapitala. Navode kako je moguće da veća integracija utječe na veću korelaciju i tržišno prelijevanje, te dodatno, kako veća međunarodna povezanost može uzrokovati i veće globalne financijske krize. Empirijskim istraživanjem su potvrdili teorijske pretpostavke te pokazali postojanje snažne međutržišne povezanosti cijena, povrata i volatilnosti. Posebno jaka veza je uočena između tržišta kapitala u SAD-u i Ujedinjenom Kraljevstvu.

U ovom će se istraživanju pobliže proučiti položaj hrvatskog tržišta kapitala u odnosu na strana tržišta. Dosadašnja su znanstvena istraživanja pokazala postojanje povezanosti između globalnih i hrvatskih tržišnih pokazatelja. Također, empirijski su potvrdila jednosmjernu uzročnost kretanja stranih tržišta kapitala na kretanja hrvatskog tržišta kapitala.

Neka su istraživanja pokušala modelirati i opisati kretanja na hrvatskom tržištu kapitala. Tako Škrinjarić i Kojić (2014) koriste metodologiju Markovljevih lanaca, a Škrinjarić (2014) istražuje nelinearnu vezu rizika i povrata na Zagrebačkoj burzi. Dabić i Penavin (2009) istražuju utjecaj obujma trgovanja na kretanje tržišnog indeksa CROBEX, dok Benazić (2008) VEC modelom promatra povezanost cijene dionica i deviznog tečaja u Republici Hrvatskoj. Sorić (2008) promatra utjecaj tečaja kune na vanjsko trgovinsku bilancu. Tomić i Sesar (2015) su promatrali međuovisnost indeksa industrijske proizvodnje i CROBEX indeksa, a u model su također uključili i utjecaj deviznog tečaja. Olbrys i Majewska (2014) promatraju direktne utjecaje posljednje američke krize na financijska tržišta u CEE zemljama, ali u istraživanje ne uključuju hrvatsko tržište kapitala.

Samo je nekoliko istraživanja do sada proučavalo vezu između CROBEX-a i ostalih burzovnih indeksa. Gradojevic i Dobardzic (2013) promatraju međuovisnost kapitalnih tržišta u regiji te uspoređuju CROBEX, SBITOP, CETOP, DAX i BELEX 15 indekse. Proučavajući bilateralnu i multilateralnu integraciju zemalja srednje i istočne Europe, uključujući Hrvatsku, u razdoblju od 2. siječnja 1997. do 10. lipnja 2005., Vizek i Dadić (2006) zaključuju da spomenuta integracija postoji. Dodatno, navode kako će ista vjerojatno nastaviti jačati postupnim pristupanjem zemalja srednje i istočne Europe monetarnoj uniji.

Erjavec i Cota (2007) proučavaju utjecaj europskih i američkih indeksa na CROBEX indeks u razdoblju od 2000 do 2004. Cilj istraživanja bio je zaključiti koje tržište, američko ili europsko, ima veći utjecaj na odluke na hrvatskom tržištu kapitala, odnosno na CROBEX indeks. Zaključuju da vanjski međunarodni signali imaju jači utjecaj od unutarnjih signala (lagirana vrijednost CROBEX-a od jednog dana nije bila značajna). Europski DAX30 i FTSE100 indeksi lagirani jedan dan također nisu bili značajni, dok su američki DJIA i NASDAQ indeksi bili značajni. Obujam trgovanja se koristio kao kontrolna varijabla i pokazao se značajnim u svim modelima. U modelu bez lagiranih vrijednosti u koji su uključeni samo obujam trgovanja i europski indeksi (zbog razlike u vremenskim zonama), sve varijable su značajne. Obujam trgovanja, DAX30 i FTSE100 imaju pozitivan i statistički značajan utjecaj na CROBEX, ali ipak je utjecaj obujma trgovanja izuzetno nizak te se ne može smatrati da ima ekonomski značajan utjecaj na formiranje vrijednosti CROBEX-a.

Sajter i Ćorić (2009) navode kako je povezanost američkih indeksa (DJIA, S&P500, NASDAQ) i CROBEX-a neupitna te su se usredotočili na traženje uzroka ovakve veze. Rezultati ostalih dosadašnjih istraživanja potvrđuju isto. Također, Sajter i Ćorić (2009) tvrde kako je povezanost ovih dvaju indeksa (odnosno, utjecaj američkog tržišta kapitala na hrvatsko) iracionalna, budući da ne postoje jasno izraženi snažni ekonomsko-trgovinski odnosi između ovih ekonomija koji bi opravdali ovakvu vezu. Tvrde da fenomen može biti objašnjen trima konceptima: globalnim utjecajima, zarazom i iracionalnom eskalacijom. Međutim, koristili su podatke iz razdoblja 03.01.2005 – 06.11.2008., iz čega proizlazi da su samo djelomično obuhvatili razdoblje krize, što bi moglo imati utjecaj na dobivene rezultate. Zaključci njihovog istraživanja također su pokazali povezanost između stranih i domaćeg tržišnog indeksa. Dodatno, dokazali su da loše vijesti imaju veći utjecaj na kretanje CROBEX-a u odnosu na dobre vijesti.

Navedeni su znanstveno-istraživački radovi nastali prije 2009. godine te su spomenuti odnos proučavali u pretkriznom kontekstu. S obzirom na to da postoji mogućnost da su odluke investitora već tada bile iracionalne (Sajter i Ćorić 2009), potrebno je provjeriti mogu li se isti obrasci utjecaja stranih indeksa na kretanje CROBEX indeksa pronaći i u razdoblju nakon financijske krize. Postoji li neka promjena u ponašanju investitora nakon krize?

1.2. Predmet istraživanja

Predmet istraživanja predstavlja utvrđivanje kratkoročnih utjecaja američkih S&P500 i DJI tržišnih indeksa i europskih DAX i FTSE100 indeksa na hrvatski indeks tržišta kapitala, CROBEX.

Teorijski dio rada sastojat će se od pregleda dosadašnje literature o međuovisnosti kapitalnih tržišta. Posebna pozornost bit će posvećena utjecaju koji informacije sa stranih tržišta kapitala imaju na hrvatsko tržište kapitala.

Empirijski dio rada ponuditi će rezultate vektorskih autoregresijskih modela (VAR modela) temeljene na dnevnim podacima koji će procijeniti međuodnose i utjecaj američkih indeksa S&P500 i DJI te europskih indeksa DAX i FTSE100 na hrvatski CROBEX indeks. Istraživanje će obuhvatiti dnevne podatke o zaključnim vrijednostima indeksa u poslijekriznom razdoblju od

1.1.2012. do 31.12.2016., kako bi se utvrdilo jesu li obrasci međuovisnosti kretanja indeksa zabilježeni u znanstvenim radovima prije krize (Vizek i Dadić 2006; Erjavec i Cota 2007; Sajter i Ćorić 2009) zadržali svoje karakteristike.

1.3. Svrha i ciljevi istraživanja

Svrha ovoga istraživanja je utvrditi utjecaje i povezanost kretanja na stranim tržištima kapitala s kretanjima na domaćem tržištu kapitala. Kretanja na stranim tržištima kapitala u ovom će radu biti predstavljena kroz američke indekse S&P500 i DJI, europske indekse DAX i FTSE100, dok će hrvatsko tržište kapitala biti predstavljeno CROBEX indeksom Zagrebačke burze. Rezultati ovoga istraživanja značajni su za investitore koji donose odluke o ulaganju na hrvatskom tržištu kapitala.

Ciljevi istraživanja su:

- Utvrditi postoji li povezanost kretanja stranih tržišta kapitala s hrvatskim tržištem kapitala;
- Utvrditi postoji li uzročnost kretanja stranih tržišta kapitala na hrvatsko tržište kapitala;
- Odrediti vremenski odmak potreban za prilagođavanje kretanja na domaćem tržištu kapitala;
- Odrediti smjer i jačinu spomenutih utjecaja;
- Utvrditi koji strani indeks, S&P500, DJI, DAX ili FTSE100, ima najveći utjecaj na kretanje domaćeg indeksa CROBEX;
- Utvrditi na koji način zaključci ovoga istraživanja mogu doprinijeti kvalitetnijim investicijskim odlukama investitora na hrvatskom tržištu kapitala.

1.4. Istraživačka hipoteza

Na osnovu navedenog problema i predmeta istraživanja,formira se temeljna i četiri pomoćne hipoteze koje će se u radu testirati.

1.4.1. Temeljna hipoteza

H1: Postoji utjecaj kretanja stranih tržišta kapitala na kretanja hrvatskog tržišta kapitala.

1.4.2. Pomoćne hipoteze

H1a: Postoji utjecaj kretanja S&P500 indeksa na kretanje indeksa CROBEX.

H1b: Postoji utjecaj kretanja DJI indeksa na kretanje indeksa CROBEX.

H1c: Postoji utjecaj kretanja FTSE100 indeksa na kretanje indeksa CROBEX.

H1d: Postoji utjecaj kretanja DAX indeksa na kretanje indeksa CROBEX.

1.5. Metode istraživanja

U ovome istraživanju primjenjuje se pozitivistički pristup istraživanju. Unaprijed postavljene hipoteze testiraju se statističkim metodama. U svrhu istraživanja koristit će se sekundarni podaci o kretanjima domaćeg CROBEX indeksa, stranih američkih S&P500 i DJI indeksa te europskih indeksa DAX i FTSE100. Podaci o CROBEX indeksu bit će pribavljeni s internet stranice Zagrebačke burze, podaci o S&P500 i DJI indeksu sa stranice Yahoo Finance, a podaci o DAX indeksu i FTSE100 indeksu sa stranice Google Finance.

Kvantitativna analiza podataka bit će provedena pomoću nekoliko statističkih testova: test stacionarnosti, test odabira duljine odmaka, VAR test, Grangerov test uzročnosti, i sličnih testova, ukoliko bi isti više odgovarali karakteristikama prikupljenih podataka te doprinijeli kvaliteti istraživanja.

Prikupljeni će podaci biti obrađeni statističkim alatima, a rezultati će u radu biti prezentirani u obliku ispisa, tablica i grafova.

1.6. Doprinos istraživanja

Ovo istraživanje doprinije će dosadašnjoj literaturi o volatilnosti na tržištima kapitala. Poseban naglasak bit će stavljen na modeliranje volatilnosti na hrvatskom tržištu kapitala o kojem su dosadašnja istraživanja vrlo oskudna.

Ponajveći doprinos ovo istraživanje predstavlja za investitore na hrvatskom tržištu kapitala,stoga što će dobiti jasniji uvid u utjecaje i povezanost kretanja na hrvatskom tržištu kapitala sa stranim utjecajima.

Dosadašnja su istraživanja na ovu temu pokrila razdoblje od 1997. do 2005. Vizek i Dadić (2006), od 2000. do 2004. Erjavec i Cota (2007) te od 2005. do 2008. godine Sajter i Ćorić (2009). Ovo istraživanje bit će usredotočeno na razdoblje nakon krize, odnosno provjerit će se postoje li ranije uočeni obrasci kretanja indeksa i nakon krize u razdoblju od 1.1.2012. do 31.12.2016. godine.

1.7. Struktura rada

Diplomski rad sastoji se od 6 poglavlja. Prvo poglavlje je uvod u kojem se opisuju problem, predmet te svrha i ciljevi istraživanja, navode se istraživačke hipoteze i opisuje metodologija istraživanja.

Drugo poglavlje donosi pregled dosadašnje teorijske i empirijske literature o volatilnosti na tržištima kapitala.

Treće poglavlje ukratko opisuje karakteristike i specifičnosti pojedinih tržišta kapitala koja se istražuju u ovom radu. Posebna pažnja posvećena je domaćem tržištu kapitala.

Četvrto poglavlje opisuje prikupljene podatke te predstavlja provedenu statističku analizu. U ovom će poglavlju biti detaljnije opisani postupci, metode i statistički testovi provedeni u svrhu testiranja hipoteza.

Peto poglavlje iznosi rezultate provedenog empirijskog istraživanja uz osvrt na temeljnu istraživačku i pomoćne hipoteze koje će se, u odnosu na dobivene rezultate, prihvatiti ili odbaciti.

Šesto poglavlje prikazuje najvažnije zaključke koji proizlaze iz provedenog istraživanja.

2. PREGLED LITERATURE

U ovome dijelu rada prezentirani su radovi na temu financijskog prelijevanja između velikih razvijenih svjetskih kapitalnih tržišta te isto tako i radovi u kojima se ispituje utjecaj spomenutoga prelijevanja na tržišta u razvoju kao što je i hrvatsko. Poneka istraživanja uzimaju u obzir i druge varijable poput postojanja krize u promatranom razdoblju, promjene deviznog tečaja, različite pravne i računovodstvene standarde, volumen trgovanja, indeks industrijske proizvodnje itd. Ili koriste različite statističke metode kako bi na više načina ispitali spomenute efekte.

Friedman i Shachmurove (1997) ispituju dinamičke veze između osam glavnih europskih tržišta. Napominju važnost političkih događanja na sve veću povezanost europskih zemalja u navedenom razdoblju, kao na primjer sporazum iz Maastrichta 1991. godine., ali također upozoravaju i na probleme vezane uz različite pravne i računovodstvene standarde u europskim zemljama. Promatraju međuovisnosti dnevnih prinosa indeksa tržišta Belgije, Britanije, Danske, Francuske, Njemačke, Italije, Nizozemske i Španjolske u razdoblju od 1988. do 1994. i zaključuju kako su ova tržišta međusobno visoko korelirana.

Morana i Beltratti (2008) promatraju mjesečne promjene na dioničkim tržištima u SAD-u, Ujedinjenom Kraljevstvu, Njemačkoj i Japanu u razdoblju od 1974 do 2004. U svome radu predstavljaju teorijski okvir prema kojemu veća međunarodna integracija vodi do veće povezanosti cijena, povrata, volatilnosti i korelacije na tržištima kapitala. Navode kako je moguće da veća integracija utječe na veću korelaciju i tržišno prelijevanje, a kako veća međunarodna povezanost može uzrokovati i veće globalne financijske krize. Svojim empirijskim istraživanjem potvrdili su teorijske pretpostavke te pokazali postojanje snažne međutržišne povezanosti cijena, povrata i volatilnosti. Posebno jaka veza je uočena između tržišta kapitala u SAD-u i Ujedinjenom Kraljevstvu.

Białkowski, Bohl i Serwa (2006) istražuju financijsko prelijevanje između kapitalnih tržišta tijekom mirnih i turbulentnih razdoblja. Potvrđuju da je pojava financijskog prelijevanja češća u

turbulentnim situacijama krize negoli u mirnim razdobljima, ipak u konačnici odbacuju hipotezu o postojanju snažnog utjecaja američkog financijskog tržišta na ostala financijska tržišta.

Prema Tomić, Sesar i Džaja (2014) ekonomska kriza u širem smislu, koja se 2007. godine dogodila u SAD-u, generirala je i ekonomsku krizu na području Eurozone, odnosno krizu na globalnoj razini. Industrijsko-financijska povezanost SAD-a i Europe doprinijela je bržem „razvoju“ krize i širenju krize na tržišta kapitala u Europi. Autori opisuju utjecaj vodećeg američkog Dow Jones Industrial Average indeksa na europsko tržište kapitala. Modelom jednostavne linearne regresije pokazuju da je s visokim postotkom pouzdanosti moguće predvidjeti kretanje vrijednosti europskog tržišta kapitala na osnovu promjene vrijednosti Dow Jones Industrial Average indeksa.

John Wei et al.(1995) proučavaju utjecaj razvijenih tržišta na tržišta u razvoju u smislu kratkoročne volatilnosti i promjena cijena. Također promatraju kako otvorenost nekog tržišta utječe na efekte porasta cijene i volatilnosti. Istraživanje je provedeno na tri razvijena tržišta New York, Tokyo i London, te dva tržišta u razvoju Tajvan i Hong Kong. Rezultati istraživanja pokazuju da je Tajvansko tržište osjetljivije od tržišta Hong Konga unatoč tome što je tržište Hong Konga otvorenije.

Olbrys i Majewska (2014) promatraju direktne utjecaje posljednje američke krize na financijska tržišta u CEE zemljama: Poljskoj, Češkoj, Mađarskoj, Slovačkoj, Litvi, Latviji, Sloveniji i Estoniji. Za svako tržište promatrali su dva stanja, rast ili pad. Zaključili su da su sve promatrane zemlje osim Slovačke u razdoblju od listopada 2007. do veljače 2009. bilježile pad tržišne aktivnosti uzrokovane američkom krizom iz 2007.

Škrinjarić i Kojić (2014) koriste metodologiju Markovljevih lanaca te je primjenjuju za predviđanje prinosa na Zagrebačkoj burzi. Markovljevi lanci jednostavna su i neparametrijska metoda još nedovoljno istražena u modeliranju prinosa.

Prema Škrinjarić (2014) uobičajeni CAPM model pretpostavlja linearnu vezu između rizičnosti i očekivanog povrata. Međutim, empirijska istraživanja pokazuju da ova veza varira tijekom godina. Stoga, autorica istražuje nelinearnu vezu rizika i povrata na Zagrebačkoj burzi, koristeći mjesečne podatke za 21 dionicu u razdoblju od siječnja 2005. do prosinca 2013. godine.

Benazić (2008) promatra povezanost cijene dionica i deviznog tečaja u Republici Hrvatskoj služeći se VEC modelom, dekompozicijom varijanci prognostičkih pogrešaka i analizom impulsnih odgovora. Analiza dugoga roka ukazuje da bi povećanje cijene dionica vodilo aprecijaciji tečaja, dok je u kratkome roku utjecaj cijene dionica na tečaj gotovo neznačajan. Dodatno, analiza impulsnih odgovora također ukazuje na to da bi povećanje cijene dionica utjecalo na aprecijaciju tečaja.

Sorić (2008) analizira vanjsko trgovinsku bilancu i njezine determinante. Predlaže četiri modela, a posebna je pažnja posvećena utjecaju tečaja kune. Kako dakle promjena tečaja kune utječe na hrvatsku vanjsko trgovinsku bilancu? Rezultati istraživanja pokazuju da nepovoljni ishodi hrvatske vanjsko trgovinske bilance ne mogu biti riješeni monetarnim instrumentima i mjerama.

Dabić i Penavin (2009) provode analizu slučaja tržišnog indeksa CROBEX te komparativnu analizu spomenutoga s Dow Jones indeksom, polazeći od pretpostavke kako je volumen prometa dionicama na tržištu jedan od faktora koji formira vrijednost tržišnog indeksa. Rezultati ovoga istraživanja pokazuju kako postoji očita veza između volumena prometa dionicama na tržištu i vrijednosti tržišnog indeksa te naglašavaju kako je spomenuta veza obrnuto proporcionalna s dubinom tržišta kapitala. U slučaju CROBEX indeksa pokazalo se kako je korelacija između volumena prometa dionicama na tržištu i vrijednosti tržišnog indeksa vrlo visoka 0,655, dok je u slučaju Dow Jones indeksa spomenuta korelacija prilično slabija i suprotnog predznaka te iznosi -0,3892.

Tomić i Sesar (2015) proučavaju industrijsku proizvodnju kao jedan od pokazatelja budućih trendova na dioničkom tržištu. Odlučili su se koristiti CROBEX indeks i pokazatelj ukupne industrijske proizvodnje Republike Hrvatske. Također su u svoje istraživanje uključili i devizni tečaj kao kontrolnu varijablu. Analizu su proveli služeći se vektorskim autoregresijskim modelom (VAR), dekompozicijom varijance i impulsnim odazivom ključnih varijabli. Rezultati potvrđuju postojanje uzročne veze deviznog tečaja na indeks industrijske proizvodnosti, kao i postojanje uzročne veze indeksa industrijske proizvodnosti na CROBEX indeks.

Samo je nekoliko istraživanja do sada proučavalo vezu između CROBEX-a i ostalih burzovnih indeksa. Gradojevic i Dobardzic (2013) promatraju međuovisnost kapitalnih tržišta u regiji te uspoređuju CROBEX, SBITOP, CETOP, DAX i BELEX 15 indekse. Proučavajući

bilateralnu i multilateralnu integraciju zemalja srednje i istočne Europe, uključujući Hrvatsku, u razdoblju od 2. siječnja 1997. do 10. lipnja 2005. pronalaze dominantan efekt CROBEX i CETOP indeksa na BELEX 15 te snažan utjecaj DAX indeksa na BELEX 15.

Vizek i Dadić (2006) zaključuju da spomenuta integracija postoji. Dodatno, navode kako će ista vjerojatno nastaviti jačati postupnim pristupanjem zemalja srednje i istočne Europe monetarnoj uniji.

Erjavec i Cota (2007) proučavaju utjecaj europskih i američkih indeksa na CROBEX indeks u razdoblju od 2000 do 2004. godine. Cilj istraživanja bio je zaključiti koje tržište, američko ili europsko, ima veći utjecaj na odluke na hrvatskom tržištu kapitala, odnosno na CROBEX indeks. Zaključuju da vanjski međunarodni signali imaju jači utjecaj od unutarnjih signala (lagirana vrijednost CROBEX-a od jednog dana nije bila značajna). Europski DAX30 i FTSE100 indeksi lagirani jedan dan također nisu bili značajni, dok su američki DJIA i NASDAQ indeksi bili značajni. Obujam trgovanja koristio se kao kontrolna varijabla i pokazao se značajnim u svim modelima. U modelu bez lagiranih vrijednosti u koji su uključeni samo obujam trgovanja i europski indeksi (zbog razlike u vremenskim zonama), sve varijable su značajne. Obujam trgovanja, DAX30 i FTSE100 imaju pozitivan i statistički značajan utjecaj na CROBEX, no utjecaj obujma trgovanja ipak je izuzetno nizak te se ne može smatrati da ima ekonomski značajan utjecaj na formiranje vrijednosti CROBEX-a.

Sajter i Ćorić (2009) navode kako je povezanost američkih indeksa (DJIA, S&P500, NASDAQ) i CROBEX-a neupitna te su se usredotočili na traženje uzroka ovakve veze. Rezultati ostalih dosadašnjih istraživanja potvrđuju isto. Također, Sajter i Ćorić (2009) tvrde kako je povezanost ovih dvaju indeksa (odnosno, utjecaj američkog tržišta kapitala na hrvatsko) iracionalna, budući da ne postoje jasno izraženi snažni ekonomsko-trgovinski odnosi između ovih ekonomija koji bi opravdali ovakvu vezu. Tvrde da fenomen može biti objašnjen trima konceptima: globalnim utjecajima, zarazom i iracionalnom eskalacijom. Međutim, koristili su podatke u razdoblju od 3.1.2005. do 6.11.2008., iz čega proizlazi da su samo djelomično obuhvatili razdoblje krize, što bi moglo imati utjecaj na dobivene rezultate. Zaključci njihovog istraživanja također su pokazali povezanost između stranih i domaćeg tržišnog indeksa. Dodatno, dokazali su da loše vijesti imaju veći utjecaj na kretanje CROBEX-a u odnosu na dobre vijesti.

Navedeni su znanstveno-istraživački radovi nastali prije 2009. godine te su spomenuti odnos proučavali u pretkriznom kontekstu. S obzirom da postoji mogućnost da su odluke investitora već tada bile iracionalne (Sajter i Ćorić 2009), potrebno je provjeriti mogu li se isti obrasci utjecaja stranih indeksa na kretanje CROBEX indeksa pronaći i u razdoblju nakon financijske krize. Postoji li neka promjena u ponašanju investitora nakon krize?

S obzirom na gore navedeno, osnovni predmet istraživanja predstavlja utvrđivanje kratkoročnih utjecaja američkih S&P500 i DJI tržišnih indeksa i europskih DAX i FTSE100 indeksa na hrvatski indeks tržišta kapitala, CROBEX. U svrhu istraživanja navedenog predmeta istraživanja, a u skladu s ranije navedenim zaključcima dosadašnjih istraživanja postavljamo sljedeće ciljeve ovoga istraživanja:

- Utvrditi postoji li povezanost kretanja stranih tržišta kapitala s hrvatskim tržištem kapitala;
- Utvrditi postoji li uzročnost kretanja stranih tržišta kapitala na hrvatsko tržište kapitala;
- Odrediti vremenski odmak potreban za prilagođavanje kretanja na domaćem tržištu kapitala;
- Odrediti smjer i jačinu spomenutih utjecaja;
- Utvrditi koji strani indeks, S&P500, DJI, DAX ili FTSE100, ima najveći utjecaj na kretanje domaćeg indeksa CROBEX;
- Utvrditi na koji način zaključci ovoga istraživanja mogu doprinijeti kvalitetnijim investicijskim odlukama investitora na hrvatskom tržištu kapitala.

3. TRŽIŠTA KAPITALA

U ovom su poglavlju predstavljene osnovne karakteristike tržišta kapitala koje se obrađuju u ovom radu. Također,navedene su definicije korištenih burzovnih indeksa. Osnovna svrha ovoga poglavlja je pobliže uputiti čitatelja u tematiku kapitalnih tržišta te pojasniti što su indeksi tržišta kapitala i kako su njihove vrijednosti korištene u nastavku rada.

Prema portalu Ivestopedia.com [1] (2017) indeks je pokazatelj ili mjera nečega, a u financijama se obično odnosi na statističku mjeru promjena na tržištu vrijednosnih papira. U slučaju financijskih tržišta, indeksi dionica i obveznica sastoje se od hipotetskog portfelja vrijednosnih papira koji predstavljaju određeno tržište ili njegov segment. Svaki indeks koji se odnosi na tržišta zaliha i obveznica ima svoju metodologiju obračuna. U većini slučajeva relativna promjena indeksa važnija je od stvarne numeričke vrijednosti koja predstavlja indeks. Prilikom sastavljanja investicijskih fondova pokrovitelji fonda nastoje stvoriti portfelje koji odražavaju komponente određenog indeksa. To omogućava investitoru da kupi sigurnost koja će vjerojatno porasti i pasti zajedno s burzom u cjelini.

3.1. Američko tržište kapitala

U ovome će radu kretanje američkog tržišta kapitala biti opisano dvama indeksima; Dow Jones Industrial Average indeksom[2] i S&P500 indeksom[3].

Prema portalu Poslovni.hr[4](2017) **Dow Jones indeks** (engl. *Dow Jones index*, njem. *Dow-Jones-Index*) prosječna dnevna cijena grupe poduzeća u uzorku koji kotiraju na NYSE (*New York Stock Exchange* – Njujorška burza vrijednosnih papira) smatra se kvalitetnim pokazateljem kretanja privrednih aktivnosti. Postoji više vrsta Dow Jonesova indeksa: za industrijsku

[1] http://www.investopedia.com/terms/i/index.asp (25.7.2017.)
[2] https://finance.yahoo.com/quote/%5EDJI/history?p=^DJI(25.7.2017.)
[3] https://finance.yahoo.com/quote/%5EGSPC/history?p=%5EGSPC(25.7.2017.)
[4] http://www.poslovni.hr/leksikon/dow-jones-indeks-615 (25.7.2017.)

djelatnost (prati efekte dionica 30 najznačajnijih poduzeća), za transportne usluge (prati efekte 20 poduzeća), indeks 500 (prati efekte dionica 500 izabranih značajnih poduzeća), a postoji i indeks za efekte dionica svih poduzeća koja kotiraju na NYSE.

U ovome radu koristi se Dow Jones Industrial Average (DJIA) indeks. Prema portalu Ivestopedia.com[5] (2017) DJIA je jedan od najstarijih i najgledanijih indeksa na svijetu i uključuje tvrtke poput General Electric Company, Walt Disney, ExxonMobilCorporation i Microsoft Corporation. Naziv je dobio po svome osnivaču Charlesu Dowu i njegovom poslovnom partneru Edwardu Jonesu. Industrijski prosjek Dow Jones dizajniran je tako da služi kao aproksimacija za šire gospodarstvo SAD-a. Kada je indeks bio pokrenut, uključivao je samo 12 tvrtki koje su gotovo isključivo bile industrijske prirode. General Electric jedina je od izvornih Dow komponenti koja je još uvijek dio indeksa 2016. godine. Kako se gospodarstvo vremenom mijenja, tako se mijenja i sastav indeksa. DJIA obično mijenja sastav kada neko poduzeće doživljava financijske poteškoće i postaje manje reprezentativno za gospodarstvo, ili kada se pojavi širi gospodarski pomak. Indeks je porastao na 30 komponenti 1928. godine i ukupno je promijenio 51 komponentu. Prva promjena došla je samo tri mjeseca nakon pokretanja indeksa. U prvih nekoliko godina, sve do Velike depresije, došlo je do mnogih promjena u njegovim sastavnicama. Godine 1932. zamijenjeno je osam kompanija u sastavu DJIA indeksa. Coca-Cola i Procter & Gamble Cododa nisu indeksu u tom razdoblju, a ove dvije dionice još su uvijek dio DJIA indeksa 2017. godine. Najnovija promjena dogodila se 19. ožujka 2015., kada je Apple, Inc. zamijenio tvrtku AT & T, Inc.

U nastavku se nalazi abecednim redom popis tvrtki uključenih u DJIA prema portalu finance.yahoo.com[6]na dan 25.07.2017.:

- 3M Company
- American Express Company
- AppleInc.
- Caterpillar Inc.
- ChevronCorporation
- Cisco Systems, Inc.

[5]http://www.investopedia.com/terms/d/djia.asp(25.07.2017.)
[6]https://finance.yahoo.com/quote/%5EDJI/components?p=%5EDJI (25.07.2017)

- E. I. du Pont de Nemours andCompany
- ExxonMobilCorporation
- General Electric Company
- Intel Corporation
- InternationalBusinessMachinesCorporation
- Johnson & Johnson
- JPMorgan Chase &Co.
- McDonald's Corporation
- Merck &Co., Inc.
- Microsoft Corporation
- NIKE, Inc.
- Pfizer Inc.
- The Boeing Company
- TheCoca-Cola Company
- The Goldman Sachs Group, Inc.
- The Home Depot, Inc.
- The Procter & Gamble Company
- The Travelers Companies, Inc.
- The Walt Disney Company
- United Technologies Corporation
- UnitedHealth Group Incorporated
- Verizon Communications Inc.
- Visa Inc.
- Wal-Mart Stores, Inc.

Prema portalu Ivestopedia.com[7](2017) Indeks Standard & Poor's 500 (S&P 500) indeks je od 500 dionica koji se smatra vodećim pokazateljem američkih dionica. Sastavljen je od tvrtki koje odabiru ekonomisti. S&P 500 je ponderirani indeks tržišne vrijednosti dionica i jedan od zajedničkih pokazatelja kretanja cijena na američkom tržištu dionica. S&P 500 široko je

[7]http://www.investopedia.com/terms/s/sp500.asp(25.07.2017.)

rasprostranjen kao najprecizniji mjerač performansi američkih dionica. Smatra se reprezentativnim za tržište jer uključuje značajan dio ukupne vrijednosti tržišta. 500 tvrtki uključenih u S&P 500 odabire S&P indeksni odbor, tim analitičara i ekonomista u tvrtki Standard & Poor's. Ti stručnjaci razmatraju različite čimbenike pri određivanju 500 dionica koje su uključene u indeks, uključujući veličinu tržišta, likvidnost i grupiranje industrije. S&P 500 postao je najpopularniji indeks američkog tržišta, lagano zamjenjujući Dow Jones Industrial Average (DJIA). S&P 500 percipiran je kao reprezentativniji na tržištu jer u svome sastavu broji 500 tvrtki, u usporedbi s DJIA indeksom koji se sastoji od 30 dionica. Tu je i velika razlika u tome kako su tvrtke zastupljene u kojem indeksu. S&P 500 koristi metodologiju ponderiranja tržišne kapitalizacije, dajući veću težinu većim tvrtkama, dok DJIA koristi metodologiju ponderiranja cijena koja skupljim dionicama daje veću težinu.

3.2. Europsko tržište kapitala

Kao pokazatelji europskog tržišta kapitala izabrana su dva indeksa. Indeks Londonske burze i DAX indeks koji je glavni pokazatelj kretanja na Njemačkom tržištu kapitala.

Prema portalu Investopedia.com[8] (2017) DAX indeks predstavlja 30 najvećih i najlikvidnijih njemačkih tvrtki koje trguju na Burzi u Frankfurtu. Za izračun indeksa koristi se metodologija slobodnog kretanja (freefloat)[9], koja u izračun tržišnu vrijednost dionica isključujući vrijednost dionica u vlasništvu kompanije, u kombinaciji s mjerom prosječnog volumena trgovanja. DAX je nastao 1988. godine s temeljnim indeksom vrijednosti od 1.000. Tvrtke članice DAX predstavljaju oko 75% ukupne tržišne kapitalizacije koja se trguje na Frankfurtskoj burzi.

DAX indeks prema portalu finance.yahoo.com[10] na dan 25.07.2017. uključuje sljedeće kompanije:

- E.ON SE
- Deutsche Lufthansa Aktiengesellschaft

[8] http://www.investopedia.com/terms/d/dax.asp(25.07.2017.)
[9] http://www.investopedia.com/terms/f/freefloatmethodology.asp(25.07.2017.)
[10] https://finance.yahoo.com/quote/%5EGDAXI/components?p=%5EGDAXI(25.07.2017.)

- Linde Aktiengesellschaft
- Vonovia SE
- Daimler AG
- Volkswagen Aktiengesellschaft
- Adidas AG
- ProSiebenSat.1 Media SE
- Beiersdorf Aktiengesellschaft
- BayerischeMotorenWerkeAktiengesellschaft
- HeidelbergCement AG
- Deutsche Telekom AG
- ThyssenKrupp AG
- Infineon Technologies AG
- Merck KommanditgesellschaftaufAktien
- BASF SE
- SAP SE
- BayerAktiengesellschaft
- Fresenius SE &Co. KGaA
- RWE Aktiengesellschaft
- Deutsche Post AG
- ContinentalAktiengesellschaft
- Siemens Aktiengesellschaft
- FreseniusMedical Care AG &Co. KGAA
- Henkel AG &Co. KGaA
- MünchenerRückversicherungs-GesellschaftAktiengesellschaft
- Allianz SE
- Deutsche BörseAktiengesellschaft
- Commerzbank AG
- Deutsche Bank Aktiengesellschaft

Prema Investopedia.com [11] (2017) FTSE tvrtka je slična Standard & Poor's, koja je specijalizirana za izračun indeksa. Dok FTSE nije dio burze, jedan suvlasnik je Londonska burza (LSE). Financial Times drugi je vlasnik i djelomični imenik tvrtke. Najpoznatiji indeks među FTSE indeksima je FTSE100.Ovaj indeks, poznatiji na Footsie-u, nedvojbeno je najpopularniji i najčešće korišten indeks tržišta dionica širom svijeta. Taj indeks pokriva otprilike 80% tržišne kapitalizacije LSE-a. Veće tvrtke čine veći dio indeksa jer se ponderira tržišnom kapitalizacijom. FTSE100 upravlja FTSE Group. Izračunava se u realnom vremenu, a kada je tržište otvoreno, ažurira se i objavljuje svakih 15 sekundi. Sastavnice ili tvrtke koje će se sastojati od FTSE100 određene su kvartalno, obično u srijedu nakon prvog petka u mjesecima ožujka, lipnja, rujna i prosinca. Svaka promjena tvrtki koje su uključene u indeks vrši se na temelju vrijednosti koje su imale tvrtke nakon zatvaranja poslovne djelatnosti noć prije nego se recenzije provode.

Trideset najznačajnijih kompanija koje sudjeluju u formiranju FTSE100 indeksa na dan 26.07.2017. prema portalu finance.yahoo.com[12] su:

- Rolls-Royce Holdings plc
- Centrica plc
- Sky plc
- GKN plc
- SSE plc
- easyJetplc
- TUI AG
- BAE Systems plc
- Ashtead Group plc
- Experian plc
- Worldpay Group plc
- Coca-Cola HBC AG
- Vodafone Group plc
- Carnival plc
- Tesco PLC

[11] http://www.investopedia.com/terms/f/ftse.asp(26.07.2017.)
[12] https://finance.yahoo.com/quote/%5EFTSE/components?p=%5EFTSE(26.07.2017.)

- Compass Group PLC
- Persimmonplc
- Schrodersplc
- Direct Line Insurance Group PLC
- Royal DutchShell plc
- MediclinicInternational plc
- Reckitt Benckiser Group plc
- Paddy Power Betfair plc
- St. James's Place plc
- SAB.L
- Shire plc
- Prudential plc
- British American Tobacco p.l.c.
- Provident Financial plc
- Antofagasta plc

3.3. Hrvatsko tržište kapitala

Hrvatsko je tržište kapitala u usporedbi s američkim, engleskim ili njemačkim tržištima kapitala značajno slabije razvijeno. Općenito, američko i englesko tržište kapitala može se smatrati tržišnocentrično, dok je Njemačko bankocentrično. Takvu podjelu navodi i Dalić (2002). Hrvatsko tržište kapitala također se može smatrati bankocentrično, a Dalić (2002) navodi kako su u Hrvatskoj početkom prošlog desetljeća stvoreni uvjeti za intenzivniji razvoj nebankarskih posrednika i tržišta kapitala. Dalić (2002) također uspoređuje hrvatski financijski sustav i financijske sustave naprednih tranzicijskih zemalja te zaključuje da rezultati analize pokazuju da se hrvatski bankarski sustav svojom veličinom i aktivnošću nalazi na razini naprednih tranzicijskih zemalja. Dok istovremeno tvrdi da nebankarski posrednici i tržište kapitala zaostaju za razinom razvijenosti koju su već dosegle napredne tranzicijske zemlje. Smatra kako će se zaostajanje u tom dijelu financijske razvijenosti relativno brzo smanjivati s

obzirom na aktivnosti mirovinskih fondova, rast investicijskih fondova i razvoj tržišta obveznica koji su već u tijeku.

Nedavno je pokrenuta i nova trgovinska platforma za mala i srednja poduzeća Zagrebačke burze nazvana Progress[13]. Ovim projektom Zagrebačka burza želi aktivno pomoći razvoju hrvatskog gospodarstva, čime Burza, osim mjesta trgovine, postaje katalizatorom novog rasta i napretka, kako kaže samo ime platforme. Nova platforma malim će i srednjim poduzećima, prvo iz Hrvatske, a zatim i iz regije, omogućiti da prikupe kapital za rast poslovanja putem izdavanja dionica ili da se samo listaju te na taj način testiraju atraktivnost svojih dionica na tržištu[14].

Prema Dalić (2002) nabrajanje prednosti i nedostataka tržišnocentričnog i bankocentričnog sustava implicitno navodi na zaključak da između ova dva načina organizacije financijskog sustava postoji određeni „trade-off". Međutim, u novije se vrijeme javljaju gledišta koja tvrde da suprotstavljanje bankocentričnih i tržišnocentričnih sustava nije pravilan pristup u razumijevanju veze između gospodarskog rasta i financijskog sustava. Levine (1997) stoga predlaže funkcionalni pristup financijskom razvoju. Funkcionalni pristup naglašava da banke i tržište obavljaju različite i međusobno komplementarne usluge koje imaju pozitivne implikacije za rast. Važna je, stoga, sveukupna razvijenost i dostupnost financijskih usluga, a ne način organizacije financijskog sustava. Levine (2000)ističe da je moguće da su i banke i tržišta efikasni u osiguravanju financijskih usluga na određenom stupnju ekonomskog razvoja, zbog čega je bitno osigurati pretpostavke za bolje i efikasnije funkcioniranje i banaka i tržišta.

Hrvatsko tržište kapitala u ovome radu bit će predstavljeno CROBEX indeksom[15]. Odlukom o indeksu Zagrebačke burze[16] iz 2008. godine utvrđuje se naziv indeksa Zagrebačke burze, kriteriji za odabir dionica koje ulaze u sastav indeksa, metoda izračuna i prilagođavanja baze indeksa, revizija indeksa i Komisija za indeks.

Prema Odluci o indeksu zagrebačke burze (2008), članak 5. metoda izračuna i prilagođavanja baze indeksa je sljedeća:

[13] http://zse.hr/default.aspx?id=77901 (07.08.2017.)
[14] http://zse.hr/default.aspx?id=77901 (07.08.2017.)
[15] http://zse.hr/default.aspx?id=44101&index=CROBEX (04.05.2017)
[16] http://zse.hr/userdocsimages/legal/Indeks2008.pdf(04.05.2017.)

1. Indeks se računa kao omjer slobodnog kretanja (freefloat) tržišne kapitalizacije i freefloat tržišne kapitalizacije na bazni datum.
2. Freefloat tržišna kapitalizacija određene dionice računa se kao umnožak broja izdanih dionica, freefloat faktora i zadnje cijene dionice.
3. Udjel freefloat tržišne kapitalizacije pojedine dionice u ukupnoj tržišnoj kapitalizaciji indeksa, na dan revizije, ne može prijeći 15%.
4. Ako nekom dionicom nije trgovano dotičnog dana, uzima se prethodna zadnja cijena.
5. Indeks se računa kontinuirano tijekom trgovine prema slijedećoj formuli:

$$I_t^j = \frac{\sum_{i=1}^{n} p_{i,t}^{\ j} \cdot q_{i,T} \cdot f_{i,T}}{K_T \cdot \sum_{i=1}^{n} p_{i,T} \cdot q_{i,T} \cdot f_{i,T}} \cdot B$$

I_t^j	vrijednost indeksa na dan t i vrijeme j
$p_{i,t}^{\ j}$	zadnja cijena dionica i na dan t i vrijeme j
$q_{i,T}$	broj izdanih dionica i ili njihov dio na dan revizije T
$f_{i,T}$	free float faktor dionica i na zadnji dan mjeseca koji prethodi danu revizije T
B	bazna vrijednost indeksa, iznosi 1000 na dan 1.srpnja 1997.
$p_{i,T}$	zadnja cijena dionica i na bazni datum ili na dan koji prethodi uključenju u indeks (u slučaju da su uključene kasnije)
K_T	koeficijent prilagođavanja baze indeksa na dan revizije T

Prema članku 6. iste Odluke slobodno kretanje (freefloat) tržišne kapitalizacije definirano je tako da u izračun ne ulaze:

1. dionice na računima osoba koji prelaze 5% ukupnog broja predmetnog izdanja
2. vlastite dionice izdavatelja

Revizija indeksa se, prema Odluci članak 9., obavlja po završetku trgovine, trećeg petka u mjesecu ožujku i rujnu te se primjenjuje od sljedećeg trgovinskog dana. Revizija indeksa vrši se na temelju podataka o trgovini u šestomjesečnom razdoblju koje prethodi reviziji, a sve promjene u sastavu indeksa objavit će se u javnosti.

Prema članku 13. iste Odluke Komisiju za indeks imenuje direktor Burze. Komisija će na temelju kriterija iz ove Odluke obavljati poslove vezane uz njegovo održanje i reviziju te objavu u javnosti.

Na sljedećem grafičkom prikazu može se vidjeti trenutni sastav dionica koje formiraju vrijednost CROBEX indeksa na dan 04.05.2017. U sastavu indeksa trenutno se nalazi 25 dionica, dok je prema Odluci o indeksu Zagrebačke burze, članak 4., maksimalan broj uključenih dionica 30.

Grafički prikaz 1Sastav CROBEX indeksa

Indeks CROBEX

Osnovni podaci | Sastav | Grafovi | Dokumenti | Novosti | Povijesni podaci

Simbol	Izdavatelj	Broj dionica	Zadnja cijena	Datum zadnje trgovine	Tržišna kapitalizacija	Težina
ADPL-R-A	AD Plastik d.d.	2.939.709	164,64	3.5.2017	483.993.689,76	3,60%
ADRS-P-A	Adris grupa d.d.	3.148.716	455,00	3.5.2017	1.432.665.780,00	10,64%
ARNT-R-A	Arena Hospitality Group d.d.	763.875	501,00	3.5.2017	382.701.375,00	2,84%
ATGR-R-A	Atlantic Grupa d.d.	1.500.435	781,01	3.5.2017	1.171.854.739,35	8,71%
ATPL-R-A	Atlantska plovidba d.d.	1.046.640	397,38	3.5.2017	415.913.803,20	3,09%
BLJE-R-A	Belje d.d. Darda	3.696.969	8,05	27.4.2017	29.760.600,45	0,22%
DDJH-R-A	ĐURO ĐAKOVIĆ GRUPA d.d.	3.038.674	41,89	3.5.2017	127.290.053,86	0,95%
DLKV-R-A	Dalekovod d.d.	9.887.722	22,30	3.5.2017	220.496.200,60	1,64%
ERNT-R-A	Ericsson Nikola Tesla d.d.	732.408	1.340,00	3.5.2017	981.426.720,00	7,29%
HT-R-A	HT d.d.	8.353.262	178,01	3.5.2017	1.486.964.168,62	11,05%
INGR-R-A	Ingra d.d.	12.190.680	4,69	3.5.2017	57.174.289,20	0,42%
KOEI-R-A	Končar - Elektroindustrija d.d.	1.867.179	790,00	2.5.2017	1.475.071.410,00	10,96%
KRAS-R-A	Kraš d.d.	686.811	440,02	3.5.2017	302.210.576,22	2,25%
LEDO-R-A	Ledo d.d.	166.174	3.450,00	27.4.2017	573.300.300,00	4,26%
LKPC-R-A	Luka Ploče d.d.	296.077	550,00	3.5.2017	162.842.350,00	1,21%
MAIS-R-A	Maistra d.d.	1.203.877	300,00	3.5.2017	361.163.100,00	2,68%
OPTE-R-A	OT-OPTIMA TELEKOM d.d.	28.600.564	3,75	3.5.2017	107.252.115,00	0,80%
PODR-R-A	Podravka d.d.	3.801.631	339,11	3.5.2017	1.289.171.088,41	9,58%
PTKM-R-A	Petrokemija d.d.	3.217.795	14,50	3.5.2017	46.658.027,50	0,35%
RIVP-R-A	VALAMAR RIVIERA d.d.	37.605.515	41,95	3.5.2017	1.577.551.354,25	11,72%
ULPL-R-A	Uljanik Plovidba d.d.	493.000	161,00	3.5.2017	79.373.000,00	0,59%
VDKT-R-A	Viadukt d.d.	365.450	81,90	3.5.2017	29.930.355,00	0,22%
VPIK-R-A	Vupik d.d.	601.302	18,86	27.4.2017	11.340.555,72	0,08%
ZABA-R-A	Zagrebačka banka d.d.	12.809.678	46,10	3.5.2017	590.526.155,80	4,39%
ZB-R-A	Zagrebačka burza d.d.	3.708.560	16,98	2.5.2017	62.971.348,80	0,47%

Izvor: http://zse.hr/default.aspx?id=44101&index=CROBEX (04.05.2017.)

Može se zaključiti da CROBEX indeks pokriva većinu događaja na Hrvatskom tržištu kapitala te ga se može smatrati dobrim pokazateljem tržišnih aktivnosti. U nastavku rada ovaj će se indeks koristiti kao osnovi pokazatelj hrvatskog tržišta kapitala.

4. EMPIRIJSKA ANALIZA

Empirijski će dio rada ponuditi rezultate vektorskih autoregresijskih modela (VAR modela) temeljenih na dnevnim podacima koji će procijeniti međuodnose i utjecaj američkih indeksa S&P500 i DJI, te europskih indeksa DAX i FTSE100 na hrvatski CROBEX indeks. Istraživanje će obuhvatiti dnevne podatke o zaključnim vrijednostima indeksa u poslijekriznom razdoblju od 1.1.2012. do 31.12.2016., kako bi se utvrdilo jesu li obrasci međuovisnosti kretanja indeksa zabilježeni u znanstvenim radovima prije krize (Vizek i Dadić 2006; Erjavec i Cota 2007; Sajter i Ćorić 2009) zadržali svoje karakteristike.

4.1. Podaci

Nakon formiranja baze podataka indeksa FTSE100, DAX, DJI, S&P500 i CROBEX, bilo je očito da u razdoblju 2012-2016 postoji nekoliko datuma zbog kojih se podaci ne poklapaju. Radi se o tome da u različitim državama postoje različiti neradni dani. Nepodudaranje podataka se može vidjeti na sljedećem prikazu.

Grafički prikaz 2Prikaz podataka i nepodudaranja radnih dana u različitim zemljama

	A	B	C	D	E	F	G	H	I
1	indeks	Date FTSE	FTSE Close	DJI Date	DJI Close	S&P500 Date	S&P500 Close	Datum Crobex	CROB EX
1244	1243	Dec 2 2016	6730.7	8.12.2016	19614.81055	8.12.2016	2246.189941	23.12.2016	1991.43
1245	1244	Dec 5 2016	6746.8	9.12.2016	19756.84961	9.12.2016	2259.530029	27.12.2016	1998.11
1246	1245	Dec 6 2016	6779.8	12.12.2016	19796.42969	12.12.2016	2256.959961	28.12.2016	1998.86
1247	1246	Dec 7 2016	6902.2	13.12.2016	19911.21094	13.12.2016	2271.719971	29.12.2016	1991.33
1248	1247	Dec 8 2016	6931.6	14.12.2016	19792.5293	14.12.2016	2253.280029	30.12.2016	1994.84
1249	1248	Dec 9 2016	6954.2	15.12.2016	19852.24023	15.12.2016	2262.030029		
1250	1249	Dec 12 2016	6890.4	16.12.2016	19843.41016	16.12.2016	2258.070068		
1251	1250	Dec 13 2016	6968.6	19.12.2016	19883.06055	19.12.2016	2262.530029		
1252	1251	Dec 14 2016	6949.2	20.12.2016	19974.61914	20.12.2016	2270.76001		
1253	1252	Dec 15 2016	6999	21.12.2016	19941.96094	21.12.2016	2265.179932		
1254	1253	Dec 16 2016	7011.6	22.12.2016	19918.88086	22.12.2016	2260.959961		
1255	1254	Dec 19 2016	7017.2	23.12.2016	19933.81055	23.12.2016	2263.790039		
1256	1255	Dec 20 2016	7044	27.12.2016	19945.03906	27.12.2016	2268.879883		
1257	1256	Dec 21 2016	7041.4	28.12.2016	19833.67969	28.12.2016	2249.919922		
1258	1257	Dec 22 2016	7063.7	29.12.2016	19819.7793	29.12.2016	2249.26001		
1259	1258	Dec 23 2016	7068.2	30.12.2016	19762.59961	30.12.2016	2238.830078		
1260	1259	Dec 28 2016	7106.1						
1261	1260	Dec 29 2016	7120.3						
1262	1261	Dec 30 2016	7142.8						
1263									

Izvor: Izrada autora

Stoga je prema Sajter i Ćorić (2009) potrebno isključiti podatke i pogreške nastale zbog različitih neradnih dana u različitim dijelovima svijeta. Prema tome, svi datumi koji se ne nalaze u svih pet indeksa su isključeni. Možemo primijetiti da su datumi uz dostupne vrijednosti indeksa DJI i S&P500 identični, dok se uz ostale povremeno razlikuju. Na primjer 27. prosinca 2016. je bio radni dan u Americi i u Hrvatskoj, dok u Ujedinjenom Kraljevstvu to nije bio slučaj. Stoga su podaci za 27. prosinca 2016. izbrisani iz baze te nisu korišteni u izračunima. Isti postupak je proveden za sve datume koji nisu bili radni u svim promatranim državama.

Nakon što su podaci bili formirani i uređeni, te nakon što su svi podaci koji nedostaju uklonjeni, prebačeni su iz Excela u program za statističku obradu Stata. Podaci su indeksirani te postoji ukupno 1184 dnevnih opservacija završnih cijena za sve indekse u razdoblju od 1.1.2012.

do 31.12.2016. Podacima je pridružena vremenska varijabla tako da je svakom podatku, završnoj cijeni indeksa, pridružen i njegov datum. U konačnici, pripremljeni podaci su izgledali ovako:

Grafički prikaz 3 Prikaz uređenih podataka

	A	B	C	D	E	F	G
1	indeks	date	FTSE100	DJI	S&P500	CROBEX	DAX
1165	1164	30-11-16	6783.79	19123.58	2198.81	1997.81	10640.30
1166	1165	01-12-16	6752.93	19191.93	2191.08	1986.23	10534.05
1167	1166	02-12-16	6730.72	19170.42	2191.95	1986.33	10513.35
1168	1167	05-12-16	6746.83	19216.24	2204.71	1975.54	10684.83
1169	1168	06-12-16	6779.84	19251.78	2212.23	1975.23	10775.32
1170	1169	07-12-16	6902.23	19549.62	2241.35	1988.47	10986.69
1171	1170	08-12-16	6931.55	19614.81	2246.19	1988.67	11179.42
1172	1171	09-12-16	6954.21	19756.85	2259.53	1982.98	11203.63
1173	1172	12-12-16	6890.42	19796.43	2256.96	1985.90	11190.21
1174	1173	13-12-16	6968.57	19911.21	2271.72	1984.90	11284.65
1175	1174	14-12-16	6949.19	19792.53	2253.28	1985.74	11244.84
1176	1175	15-12-16	6999.01	19852.24	2262.03	1963.53	11366.40
1177	1176	16-12-16	7011.64	19843.41	2258.07	1968.33	11404.01
1178	1177	19-12-16	7017.16	19883.06	2262.53	1967.12	11426.70
1179	1178	20-12-16	7043.96	19974.62	2270.76	1970.48	11464.74
1180	1179	21-12-16	7041.42	19941.96	2265.18	1984.46	11468.64
1181	1180	22-12-16	7063.68	19918.88	2260.96	1984.25	11456.10
1182	1181	23-12-16	7068.17	19933.81	2263.79	1991.43	11449.93
1183	1182	28-12-16	7106.08	19833.68	2249.92	1998.86	11474.99
1184	1183	29-12-16	7120.26	19819.78	2249.26	1991.33	11451.05
1185	1184	30-12-16	7142.83	19762.60	2238.83	1994.84	11481.06
1186							

Izvor: Izrada autora

Varijabla datuma je u programu Stata generirana iz string varijable kopirane iz Excela sljedećim formula:

- **gen date2 = date(date, "DMY")**
- **format date2 %td**

te postavljena kao vremenska varijabla cijele baze podataka:

- **drop date**
- **rename date2 date**

- **tset date**

time variable: date, 03jan2012 to 30dec2016, but with gaps

delta: 1 day

Ipak, neki datumi nedostaju, jer se u bazi podataka nalaze podaci samo za dane trgovanja na burzama. Stoga, ako kao vremensku komponentu podataka koristimo varijablu *date* prilikom obrade podataka poneke vrijednosti bit će izgubljene jer se na primjer za izračun dnevnih prinosa promatra današnja vrijednost indeksa i jučerašnja vrijednost indeksa. Ukoliko bismo računali prinose prema varijabli *date* kako je gore navedeno, imali bismo prilično velik broj vrijednosti koje se ne mogu izračunati. Primjerice, ne bismo mogli izračunati prinos ponedjeljkom jer je prethodna promatrana vrijednost nedjelja, neradni dan, i izgubili bismo mnogo informacija o trgovanju. Stoga, odlučeno je da se za vremensku komponentu niza koristi varijabla *indeks* jer se u tom slučaju pri izračunu prinosa promatra današnja vrijednost i vrijednost prethodnog radnog dana. Na primjeru ponedjeljka prinos se računa tako da se vrijednost na dan ponedjeljak podijeli s vrijednosti od prethodnog radnog dana, najčešće petka, osim u slučaju ako je petak neradni dan, tada se uzima vrijednost četvrtka.

Navedena korekcija učinjena je naredbom:

- **tset indeks**

time variable: indeks, 1 to 1184

delta: 1 unit

Na sljedećem prikazu nalazi se deskriptivna statistika završnih cijena na dan trgovanja za pet promatranih indeksa.

```
. sum  crobex sp500 dji ftse100 dax
```

Variable	Obs	Mean	Std. Dev.	Min	Max
crobex	1184	1779.385	93.05512	1585.73	2025.28
sp500	1184	1822.001	283.0456	1277.06	2271.72
dji	1184	16053.08	1949.791	12118.57	19974.62
ftse100	1184	6394.657	425.9652	5260.19	7142.83
dax	1184	9176.584	1536.398	6017.23	12374.73

Između nekih od promatranih indeksa postoje i prilično visoki stupnjevi korelacije. Korelacija između DAX i S&P500 indeksa iznosi 0,95, a između DAX i DJI 0,94, što je vrlo visok stupanj korelacije. CROBEX indeks ima pozitivnu korelaciju s S&P500 0,0122, s DJI 0,0678, a s FTSE100 0,4151. Korelacija između CROBEX i DAX indeksa je vrlo slaba i negativna te iznosi -0,0212.

```
. cor  crobex sp500 dji ftse100 dax
(obs=1184)
```

	crobex	sp500	dji	ftse100	dax
crobex	1.0000				
sp500	0.0122	1.0000			
dji	0.0678	0.9936	1.0000		
ftse100	0.4151	0.7320	0.7668	1.0000	
dax	-0.0212	0.9515	0.9446	0.7617	1.0000

Kretanje originalnih vrijednosti zaključnih cijena indeksa na dan trgovanja se može vidjeti na sljedećim prikazima:

Grafički prikaz 4 Kretanje zaključne cijene CROBEX indeksa na dan trgovanja u razdoblju od 2012-2016

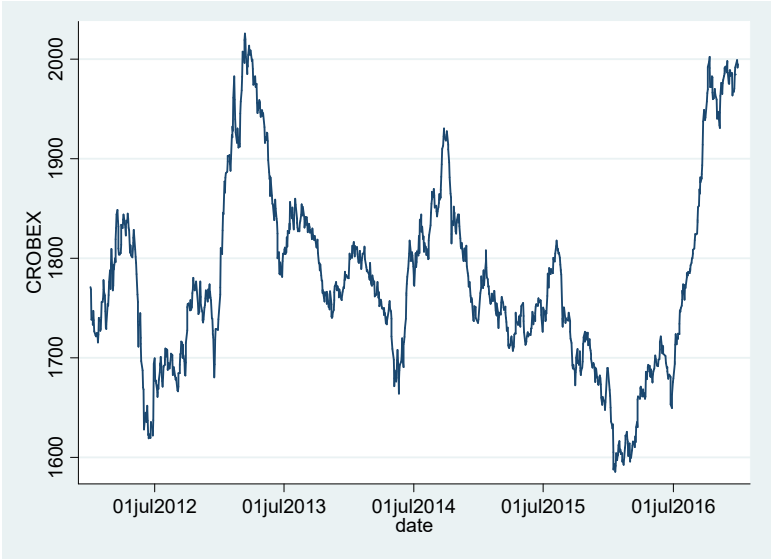

Izvor: Izrada autora

Grafički prikaz 5Kretanje zaključne cijene S&P500 indeksa na dan trgovanja u razdoblju od 2012-2016

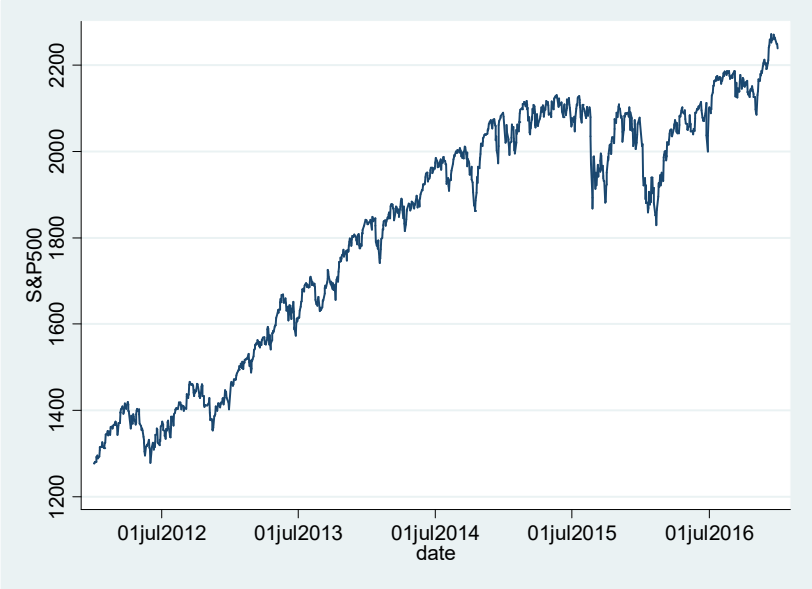

Izvor: Izrada autora

Grafički prikaz 6Kretanje zaključne cijene DJI indeksa na dan trgovanja u razdoblju od 2012-2016

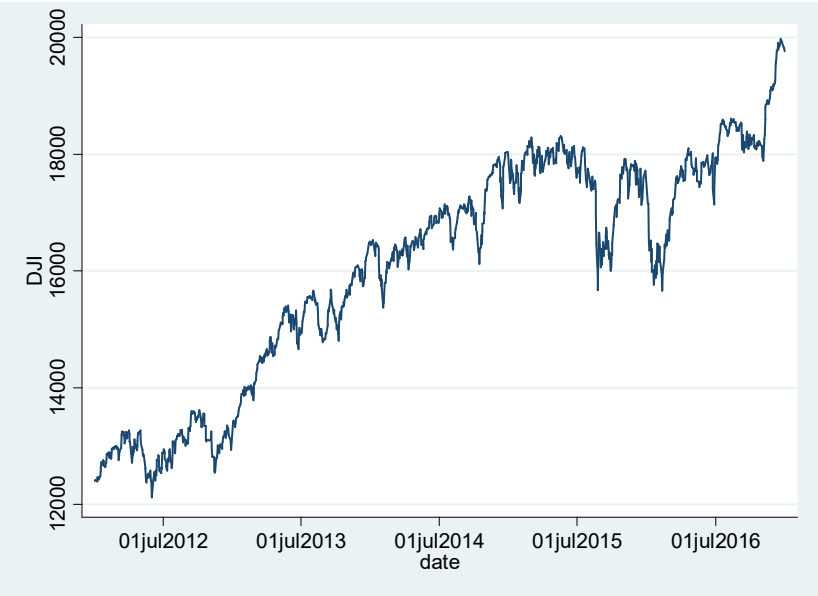

Izvor: Izrada autora

Grafički prikaz 7Kretanje zaključne cijene FTSE100 indeksa na dan trgovanja u razdoblju od 2012-2016

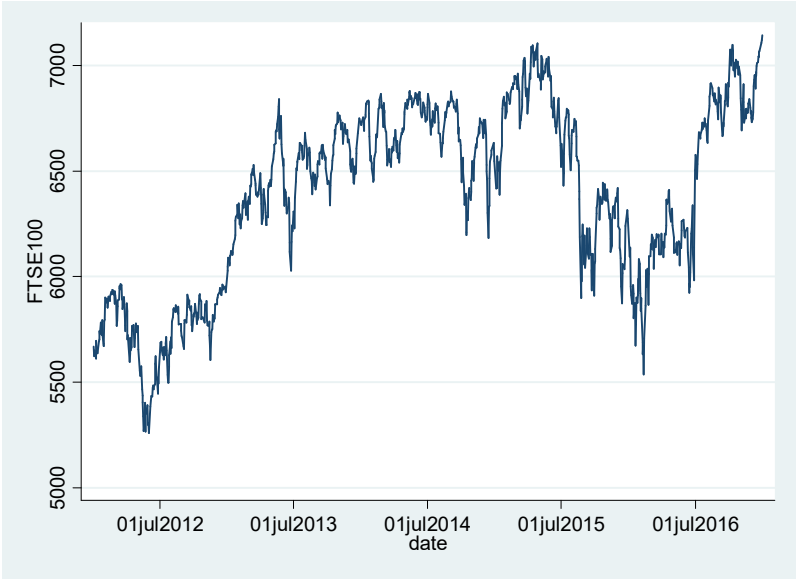

Izvor: Izrada autora

Grafički prikaz 8Kretanje zaključne cijene DAX indeksa na dan trgovanja u razdoblju od 2012-2016

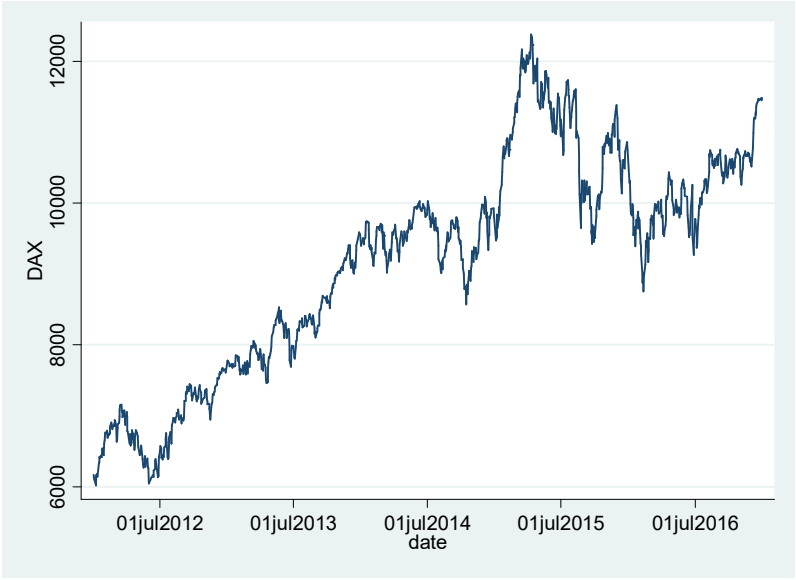

Izvor: Izrada autora

U nastavku će originalni podaci biti prilagođeni za daljnju statističku obradu. Prvo, originalni podaci prikazuju iznose zaključnih cijena na dan trgovanja, stoga će biti potrebno izračunati prinos svakoga indeksa na dan trgovanja. Završna će cijena svakog dana biti podijeljena sa završnom cijenom prethodnog radnog dana. Na primjer vrijednost zaključne cijene u ponedjeljak bit će podijeljena sa zaključnom cijenom u petak, osim ako je petak bio neradni dan, tada će se podijeliti sa zaključnom cijenom u četvrtak. Nakon toga je dobivene vrijednosti potrebno logaritmirati i diferencirati.

Originalne su vrijednosti indeksa sljedećim naredbama transformirane u prikladne podatke za statističku obradu. `1' predstavlja originalnu vrijednost svakog od indeksa.

```
gen p_`1' = `1' / l.`1' #računanje prinosa
gen lp_`1' = log(p_`1') #logaritmiranje
gen dlp_`1' = d.lp_`1'  #diferenciranje
```

Potrebno je napomenuti kako se u postupku izračuna gubi jedna opservacija jer za prvi radni dan u bazi podataka nije moguće izračunati prinos zato što ne postoji vrijednost prethodnog radnog dana. Također, u postupku diferenciranja gubi se još jedna dodatna opservacija analogno računanju prinosa. Stoga, nakon transformiranja podataka raspolažemo s ukupno 1182 opservacije.

Sljedeći postupak koji treba provesti nad podacima nakon logaritmiranja je utvrđivanje stacionarnosti vremenskih nizova za što će se koristiti Dickey-Fuller test (DF test). Hipoteza H0 Dickey-Fullerovog testa pretpostavlja postojanje jediničnog korijena, dok H1 pretpostavlja ne postojanje jediničnog korijena, tj. stacionarnost niza. Ako se pokaže da niz nije stacionaran potrebno ga je pokušati učiniti stacionarnim dodatnim postupkom diferenciranja.

```
. dfuller  dlp_crobex

Dickey-Fuller test for unit root                   Number of obs   =      1181

                               ---------- Interpolated Dickey-Fuller ---------
                  Test         1% Critical       5% Critical      10% Critical
               Statistic           Value             Value             Value
------------------------------------------------------------------------------
 Z(t)            -58.440            -3.430            -2.860            -2.570
------------------------------------------------------------------------------
MacKinnon approximate p-value for Z(t) = 0.0000
```

Prema Dickey-Fullerovom testu možemo odbaciti H0 hipotezu (0,00<0,05) tj. zaključiti da ne postoji jedinični korijen i da je niz diferenciranih logaritmiranih prinosa CROBEX-a stacionaran.

```
. dfuller   dlp_sp500

Dickey-Fuller test for unit root                   Number of obs   =      1181

                               ---------- Interpolated Dickey-Fuller ---------
                  Test         1% Critical       5% Critical      10% Critical
               Statistic           Value             Value             Value
------------------------------------------------------------------------------
 Z(t)            -58.659            -3.430            -2.860            -2.570
------------------------------------------------------------------------------
MacKinnon approximate p-value for Z(t) = 0.0000
```

Prema Dickey-Fullerovom testu možemo odbaciti H0 hipotezu (0,00<0,05) tj. zaključiti da ne postoji jedinični korijen i da je niz diferenciranih logaritmiranih prinosa S&P500 indeksa stacionaran.

```
. dfuller   dlp_dji

Dickey-Fuller test for unit root                   Number of obs   =      1181

                               ---------- Interpolated Dickey-Fuller ---------
                  Test         1% Critical       5% Critical      10% Critical
               Statistic           Value             Value             Value
------------------------------------------------------------------------------
 Z(t)            -59.967            -3.430            -2.860            -2.570
------------------------------------------------------------------------------
MacKinnon approximate p-value for Z(t) = 0.0000
```

Prema Dickey-Fullerovom testu možemo odbaciti H0 hipotezu (0,00<0,05) tj. zaključiti da ne postoji jedinični korijen i da je niz diferenciranih logaritmiranih prinosa DJI indeksa stacionaran.

```
. dfuller   dlp_ftse100

Dickey-Fuller test for unit root                   Number of obs   =      1181

                               ---------- Interpolated Dickey-Fuller ---------
                  Test         1% Critical       5% Critical      10% Critical
               Statistic           Value             Value             Value
------------------------------------------------------------------------------
 Z(t)            -57.734            -3.430            -2.860            -2.570
------------------------------------------------------------------------------
MacKinnon approximate p-value for Z(t) = 0.0000
```

Prema Dickey-Fullerovom testu možemo odbaciti H0 hipotezu (0,00<0,05) tj. zaključiti da ne postoji jedinični korijen i da je niz diferenciranih logaritmiranih prinosa FTSE100 indeksa stacionaran.

```
. dfuller   dlp_dax

Dickey-Fuller test for unit root                   Number of obs   =      1181

                               ---------- Interpolated Dickey-Fuller ---------
                  Test         1% Critical       5% Critical      10% Critical
               Statistic           Value             Value             Value
------------------------------------------------------------------------------
 Z(t)            -58.412            -3.430            -2.860            -2.570
------------------------------------------------------------------------------
MacKinnon approximate p-value for Z(t) = 0.0000
```

Prema Dickey-Fullerovom testu možemo odbaciti H0 hipotezu (0,00<0,05) tj. zaključiti da ne postoji jedinični korijen i da je niz diferenciranih logaritmiranih prinosa DAX indeksa stacionaran.

Podaci su dakle pripremljeni za statističku obradu na sljedeći način. Uzete su zaključne dnevne vrijednosti indeksa CROBEX, S&P500, DJI, FTSE100 i DAX u razdoblju od 1.1.2012. do 31.12.2016. Uklonjeni su neradni dani u različitim državama te je zatim izračunat dnevni prinos P_t/P_{t-1}. Vrijednosti prinosa potom su logaritmirane, a nakon toga diferencirane. Ovako pripremljeni podaci mogu se koristiti kao ulazni podaci za VAR model. Postupak se može vidjeti u .do datoteci *prepare_data.do*. `1' predstavlja originalnu vrijednost svakog od indeksa.

```
capture drop p_`1'
capture drop lp_`1'
capture drop dlp_`1'
gen p_`1' = `1' / l.`1'
gen lp_`1' = log(p_`1')
gen dlp_`1' = d.lp_`1'
capture drop p_`1'
capture drop lp_`1'
```

Slijedi kratki pregled podataka prije odabira modela.

Deskriptivna statistika

```
. sum  dlp_crobex dlp_sp500 dlp_dji dlp_ftse100 dlp_dax
```

Variable	Obs	Mean	Std. Dev.	Min	Max
dlp_crobex	1182	2.68e-06	.0076619	-.0304408	.0344859
dlp_sp500	1182	-4.09e-06	.0121132	-.0482035	.0565774
dlp_dji	1182	-3.88e-06	.0116843	-.0482985	.0538447
dlp_ftse100	1182	9.30e-06	.0135038	-.0497244	.0782588
dlp_dax	1182	9.80e-06	.0175606	-.0944981	.0966856

Kao što je ranije navedeno, broj opservacija se smanjio za dvije opservacije zbog izračuna prinosa i diferenciranja. Aritmetička je sredina približno jednaka nuli što je i očekivano.

Na sljedećim prikazima nalaze se vrijednosti indeksa nakon transformacije.

Grafički prikaz 9 Diferencirane i logaritmirane vrijednosti dnevnih prinosa CROBEX indeksa

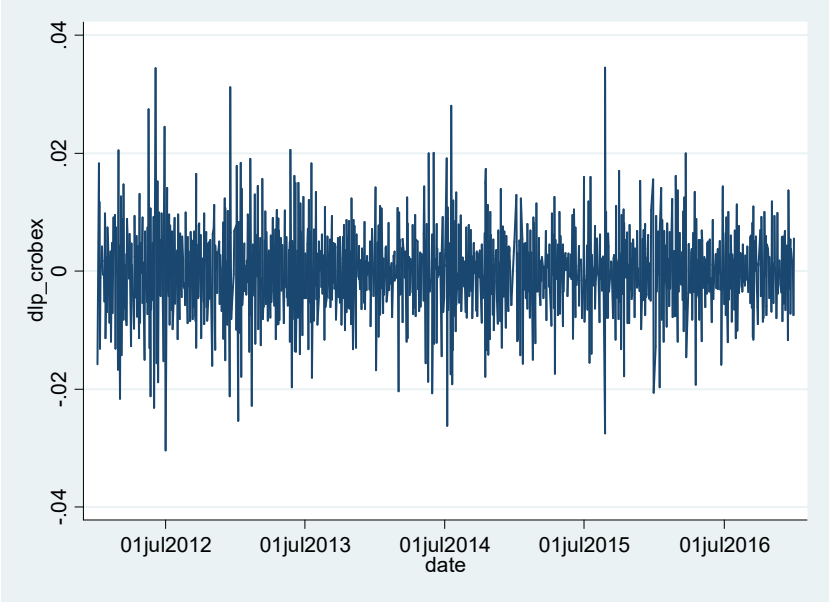

Izvor: Izrada autora

Grafički prikaz 10Diferencirane i logaritmirane vrijednosti dnevnih prinosa S&P500 indeksa

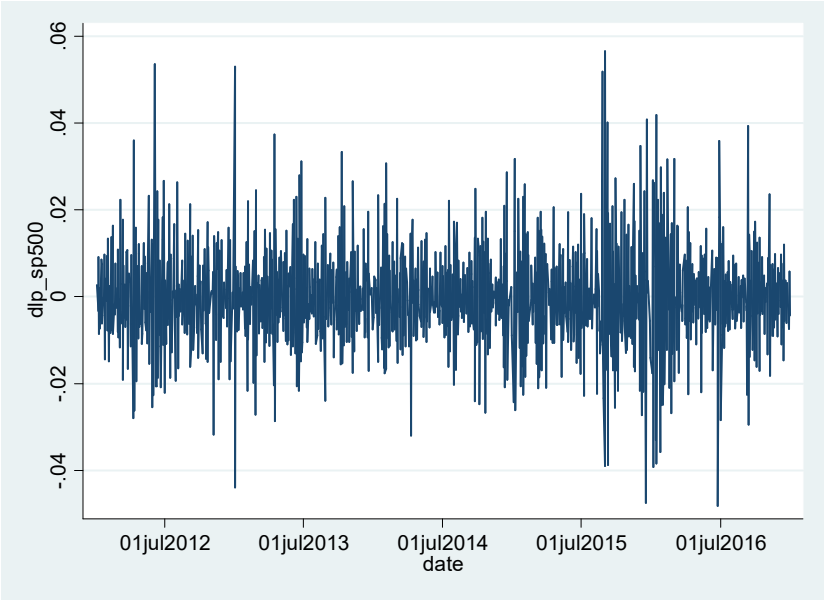

Izvor: Izrada autora

Grafički prikaz 11Diferencirane i logaritmirane vrijednosti dnevnih prinosa DJI indeksa

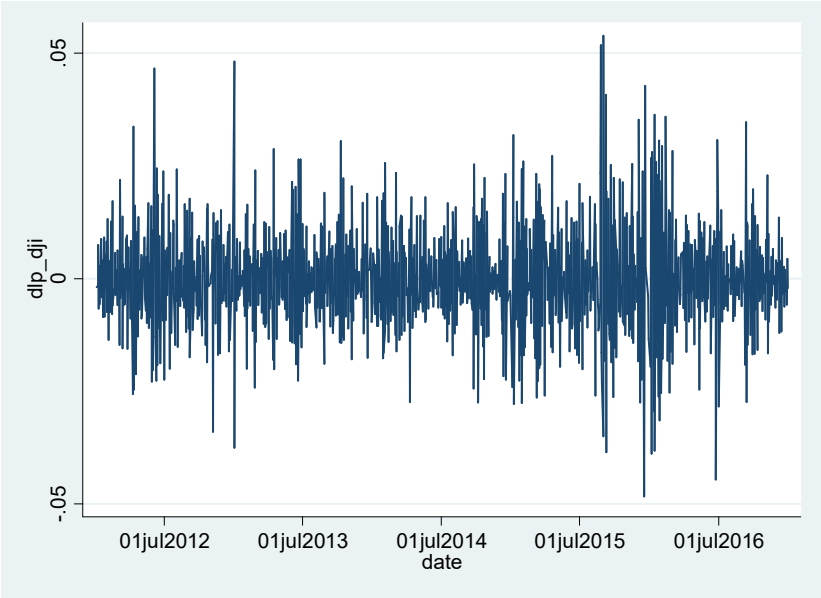

Izvor: Izrada autora

Grafički prikaz 12Diferencirane i logaritmirane vrijednosti dnevnih prinosa FTSE100 indeksa

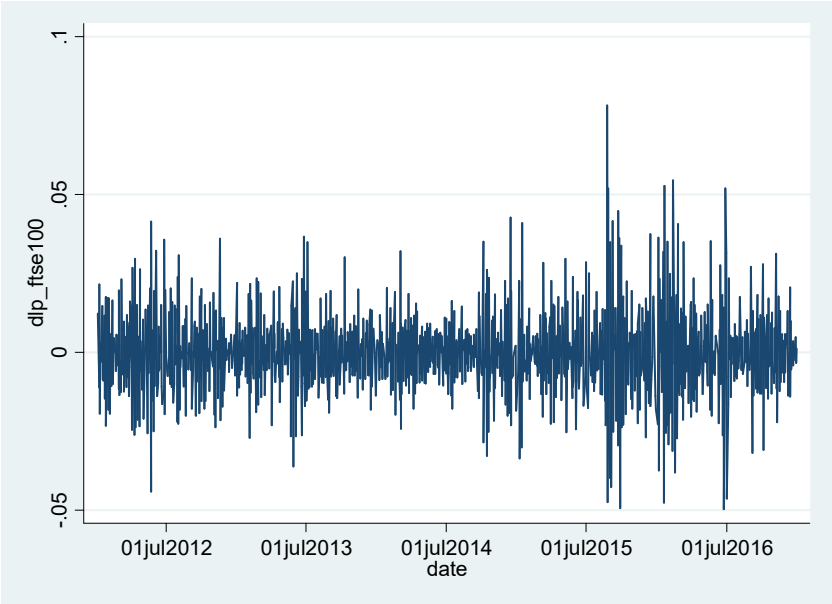

Izvor: Izrada autora

Grafički prikaz 13Diferencirane i logaritmirane vrijednosti dnevnih prinosa DAX indeksa

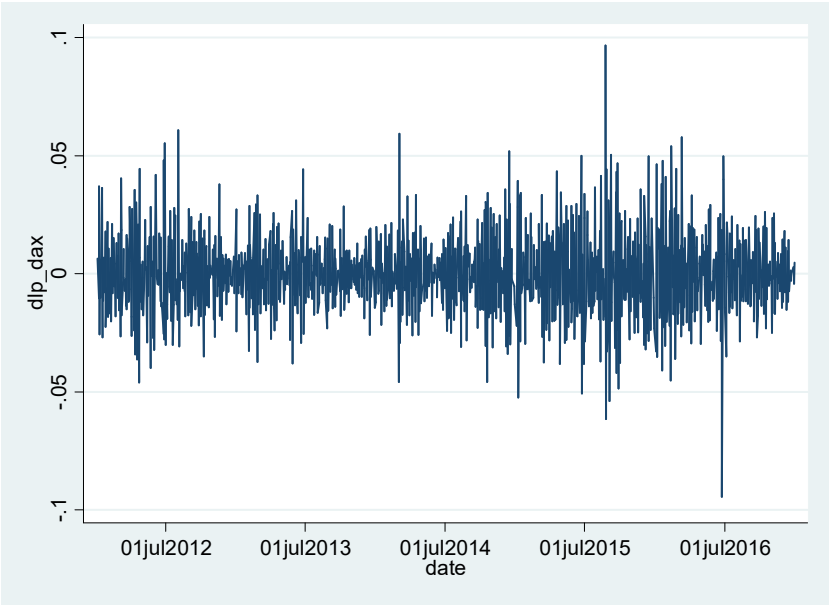

Izvor: Izrada autora

Korelacija

```
. cor  dlp_crobex dlp_sp500 dlp_dji dlp_ftse100 dlp_dax
(obs=1182)

             | dlp_cr~x dlp_~500  dlp_dji dlp_~100  dlp_dax
-------------+------------------------------------------------
  dlp_crobex |   1.0000
   dlp_sp500 |   0.0856   1.0000
     dlp_dji |   0.0893   0.9723   1.0000
 dlp_ftse100 |   0.1927   0.5089   0.5166   1.0000
     dlp_dax |   0.2116   0.5149   0.5229   0.8278   1.0000
```

Iz priloženog ispisa korelacija možemo vidjeti da je korelacija između američkih indeksa DJI i S&P500 vrlo jaka i pozitivna te iznosi 0,97. Korelacija između europskih indeksa FTSE100 i DAX također je vrlo jaka i pozitivna te iznosi 0,83. Korelacija CROBEX indeksa s ostalim indeksima relativno je slaba, ali pozitivna kao što je i očekivano. Korelacija s S&P500 indeksom iznosi 0,0856, a s DJI indeksom 0,0893. Korelacija CROBEX indeksa s FTSE100 indeksom iznosi 0,1927, a s DAX indeksom 0,2116. Isto se može vidjeti i na priloženom grafikonu korelacija.

Grafički prikaz 14Korelacija između indeksa CROBEX, S&P500, DJI, FTSE100 i DAX

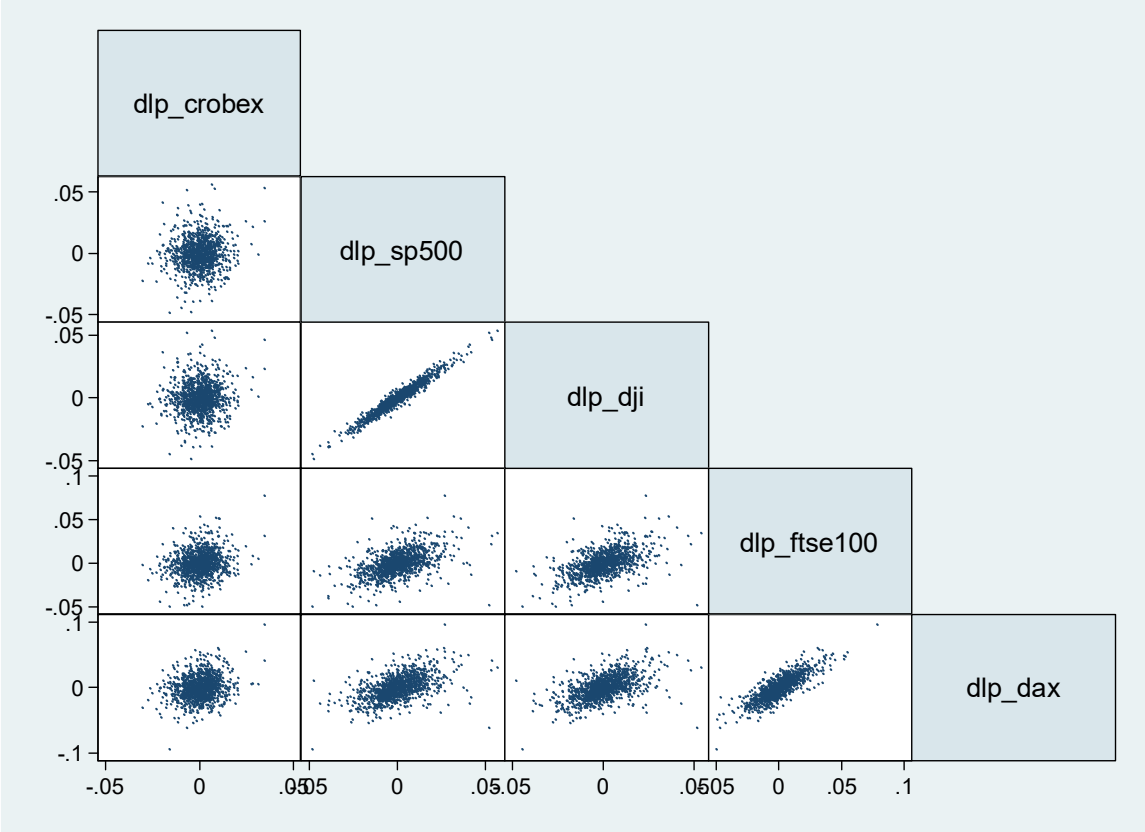

Izvor: Izrada autora

4.2. Empirijski modeli

Nakon što su podaci pripremljeni može se pristupiti postupku odabira modela. U ovom radu posebno će se promatrati utjecaj stranih indeksa na CROBEX indeks. Zbog spomenutih vrlo visokih korelacija koje se javljaju između parova američkih i europskih indeksa odlučeno je da će se u modele uključivati po jedan od američkih i po jedan od europskih indeksa.

Prema tome, modeli će biti prikladno kreirani kako bi se mogao donijeti zaključak o postavljenim hipotezama.

- **Temeljna hipoteza**

H1: Postoji utjecaj kretanja stranih tržišta kapitala na kretanja hrvatskog tržišta kapitala.

- **Pomoćne hipoteze**

H1a: Postoji utjecaj kretanja S&P500 indeksa na kretanje indeksa CROBEX.

H1b: Postoji utjecaj kretanja DJI indeksa na kretanje indeksa CROBEX.

H1c: Postoji utjecaj kretanja FTSE100 indeksa na kretanje indeksa CROBEX.

H1d: Postoji utjecaj kretanja DAX indeksa na kretanje indeksa CROBEX.

S obzirom na ranije spomenute karakteristike prikupljenih podataka i hipoteze koje je potrebno dokazati ili opovrgnuti empirijski modeli će biti kreirani na sljedeći način. Za analizu će se koristiti VAR metodologija i provesti Grangerov test uzročnosti.

Prema Bahovec i Erjavec (2009) VAR modeli dinamički su modeli skupine vremenskih nizova i generalizacija su dinamičkih modela definiranih na osnovi jedne jednadžbe. Rezultati dobiveni analizom VAR modela osnova su za razumijevanje i istraživanje međuovisnosti u skupu ekonomskih varijabli te definiranje strukturnih ekonometrijskih modela. VAR modeli koriste se također u analizi Grangerove uzročnosti i inovacijskoj analizi. Dvije osnovne primjene VAR metodologije koja je danas postala ključni alat moderne ekonometrije. VAR modeli koriste se u formalnom testiranju ekonomskih teorija koje pretpostavljaju određene oblike povezanosti ekonomskih varijabli te u analizi dinamike pojava u prethodnim razdobljima. Opći oblik Simsovog VAR modela (eng. General unrestricted VAR model) ne pretpostavlja nikakva ograničenja na parametre modela i sve varijable tretiraju se simetrično, tj. varijable se unaprijed ne klasificiraju na endogene (zavisne) i egzogene(nezavisne).

Ispitivanje Grangerove uzročnosti prema Bahovec i Erjavec (2009) popularna je metoda i često se primjenjuje u ekonometrijskim analizama. Često je u različitim područjima ekonomije

potrebno ustanoviti uzrokuje li pojava X pojavu Y u Grangerovom smislu i obrnuto, uzrokuje li pojava Y pojavu X, tj. postoji li jednosmjerna uzročnost među pojavama ili, primjerice, obje pojave uzrokuju jedna drugu pa se radi o dvosmjernoj uzročnosti.

Friedman i Shachmurove (1997) također koriste VAR model i Grangerov test uzročnostite navode sljedeće osnovne prednosti ove metodologije. Grangerov test uzročnosti, prema Granger (1969), jednostavan je način utvrđivanja utječu li na određeno tržište inovacije na drugim tržištima. Test ukazuje na to mogu li se inovacije na jednom tržištu predvidjeti u jednom koraku na drugom tržištu. Važna prednost ovog testa je, navode, da poredak varijabli u VAR modelu ne utječe na rezultate testa.

Istraživanje će se provesti ocjenjivanjem dva modela. Model A će sadržavati varijable CROBEX, S&P500 i FTSE100 indeksa, dok će Model B uključivati CROBEX te preostala dva indeksa DJI i DAX. Odluka o izboru ovakvih modela proizlazi iz činjenice da je korelacija između američkih S&P500 i DJI indeksa vrlo visoka te ih nije preporučljivo staviti u isti model zbog problema multikolinearnosti. Isto vrijedi i za Europske indekse FTSE100 i DAX. U model A bit će uključen jedan američki i jedan europski indeks koji pokazuju viši stupanj korelacije s CROBEX indeksom u odnosu na drugi indeks iz grupe. Preostala dva indeksa bit će s CROBEX indeksom uključeni u Model B. S obzirom na to da je utjecaj stranih indeksa na CROBEX indeks u fokusu istraživanja ovoga rada, CROBEX će biti uključen u oba modela.

Prema tome, VAR model Model A uključuje varijable:

- *dlp_sp500*
- *dlp_ftse100*
- *dlp_crobex*

VAR model Model B uključuje varijable:

- *dlp_dji*
- *dlp_dax*
- *dlp_crobex*

U procesu provođenja VAR metodologije nakon odabira varijabli uključenih u model potrebno je pristupiti odabiru optimalnog vremenskog pomaka za provođenje analize. Navedeno se u statističkom programu Stata provodi pomoću naredbe *varsoc*. Funkcija *varsoc* prema

zadanim početnim postavkama koristi pomake od 1 do 4. Ipak, s obzirom na to da se u ovom istraživanju koriste dnevni podaci na dan trgovanja, maksimalan broj odmaka je postavljen na 14.

```
. varsoc  dlp_sp500 dlp_ftse100 dlp_crobex, maxlag(14)

Selection-order criteria
Sample:  17 - 1184                          Number of obs      =      1168
```

lag	LL	LR	df	p	FPE	AIC	HQIC	SBIC
0	11099.9				1.1e-12	-19.0016	-18.9967	-18.9886
1	11692.8	1185.8	9	0.000	4.1e-13	-20.0014	-19.9818	-19.9494
2	11954.7	523.78	9	0.000	2.7e-13	-20.4345	-20.4001	-20.3434
3	12109.4	309.34	9	0.000	2.1e-13	-20.6839	-20.6348	-20.5539
4	12192.1	165.37	9	0.000	1.8e-13	-20.8101	-20.7463	-20.641
5	12262.6	141.04	9	0.000	1.7e-13	-20.9154	-20.8369	-20.7073
6	12309.4	93.625	9	0.000	1.6e-13	-20.9802	-20.887	-20.7331
7	12346	73.232	9	0.000	1.5e-13	-21.0275	-20.9195	-20.7414*
8	12363	33.851	9	0.000	1.5e-13	-21.041	-20.9184	-20.7159
9	12384.2	42.391	9	0.000	1.4e-13	-21.0619	-20.9246	-20.6978
10	12408.8	49.353	9	0.000	1.4e-13	-21.0888	-20.9367	-20.6856
11	12427.2	36.717	9	0.000	1.4e-13	-21.1048	-20.938	-20.6626
12	12446.7	39.092*	9	0.000	1.3e-13*	-21.1228*	-20.9413*	-20.6417
13	12453.9	14.269	9	0.113	1.4e-13	-21.1196	-20.9234	-20.5995
14	12460	12.186	9	0.203	1.4e-13	-21.1147	-20.9037	-20.5555

```
Endogenous:  dlp_sp500 dlp_ftse100 dlp_crobex
 Exogenous:  _cons
```

Funkcija prikazuje rezultate prema informacijskim kriterijima. Prema Bahovec i Erjavec (2009) optimalna vrijednost pomaka je određena minimiziranjem informacijskih kriterija. U ovome slučaju to bi značilo da je broj odmaka od 7 radnih dana najprikladniji te odgovara rezultatu SBIC (Schwarzovog) kriterija. Također valja napomenuti kako teorijski gledano pomak veći od 7 radnih dana ne bi imao puno smisla budući da je predmet istraživanja vezan uz financijska tržišta na kojima je stupanj informiranosti sudionika vrlo visok. Model A stoga uključuje varijable *dlp_ sp500*, *dlp_ftse100* i *dlp_ crobex*, te pomake od 1 do 7 radnih dana.

Isti postupak ponovljen je i za VAR model Model B. Rezultati prema informacijskim kriterijima ukazuju na to da je optimalan broj pomaka u Modelu B također 7. Dakle, struktura Modela B analogno strukturi Modela A uključuje varijable *dlp_ dji*, *dlp_dax* i *dlp_ crobex* te pomake od 1 do 7 radnih dana.

```
. varsoc  dlp_dji dlp_dax dlp_crobex, maxlag(14)

   Selection-order criteria
   Sample:  17 - 1184                          Number of obs      =      1168
```

lag	LL	LR	df	p	FPE	AIC	HQIC	SBIC
0	10853.3				1.7e-12	-18.5793	-18.5744	-18.5663
1	11422.7	1138.8	9	0.000	6.6e-13	-19.5389	-19.5193	-19.4869
2	11662.1	478.68	9	0.000	4.4e-13	-19.9333	-19.899	-19.8423
3	11808.4	292.77	9	0.000	3.5e-13	-20.1686	-20.1195	-20.0385
4	11883.3	149.74	9	0.000	3.1e-13	-20.2814	-20.2176	-20.1123
5	11949.5	132.48	9	0.000	2.8e-13	-20.3794	-20.3009	-20.1713
6	11989.8	80.505	9	0.000	2.7e-13	-20.4329	-20.3397	-20.1858
7	12027.5	75.348	9	0.000	2.6e-13	-20.482	-20.3741	-20.1959*
8	12043.2	31.37	9	0.000	2.5e-13	-20.4934	-20.3708	-20.1683
9	12066.5	46.68	9	0.000	2.5e-13	-20.518	-20.3806	-20.1539
10	12095.6	58.124	9	0.000	2.4e-13	-20.5523	-20.4003	-20.1492
11	12112.8	34.433	9	0.000	2.3e-13	-20.5664	-20.3996	-20.1242
12	12131.8	38.043*	9	0.000	2.3e-13*	-20.5836*	-20.4021*	-20.1024
13	12138.8	13.95	9	0.124	2.3e-13	-20.5801	-20.3839	-20.0599
14	12143.3	9.1416	9	0.424	2.3e-13	-20.5725	-20.3616	-20.0133

```
   Endogenous:  dlp_dji dlp_dax dlp_crobex
    Exogenous:  _cons
```

5. REZULTATI ISTRAŽIVANJA

Rezultati VAR modela **Model A**:

```
. var  dlp_sp500 dlp_ftse100 dlp_crobex, lags(1/7)

Vector autoregression

Sample:  10 - 1184                                No. of obs      =      1175
Log likelihood =  12422.63                        AIC             = -21.03256
FPE            =  1.47e-13                        HQIC            = -20.92519
Det(Sigma_ml)  =  1.32e-13                        SBIC            = -20.74783

Equation           Parms      RMSE     R-sq      chi2     P>chi2
----------------------------------------------------------------
dlp_sp500            22     .008985   0.4619   1008.796   0.0000
dlp_ftse100          22     .009693   0.4938   1146.287   0.0000
dlp_crobex           22     .005798   0.4332    898.218   0.0000
----------------------------------------------------------------
```

	Coef.	Std. Err.	z	P>|z|	[95% Conf.	Interval]
dlp_sp500						
dlp_sp500						
L1.	-.9121167	.0380898	-23.95	0.000	-.9867714	-.8374621
L2.	-.8416244	.0580804	-14.49	0.000	-.95546	-.7277888
L3.	-.7309294	.0699161	-10.45	0.000	-.8679625	-.5938963
L4.	-.5834015	.0740318	-7.88	0.000	-.7285012	-.4383018
L5.	-.464231	.07054	-6.58	0.000	-.6024869	-.3259752
L6.	-.3716993	.0596388	-6.23	0.000	-.4885892	-.2548095
L7.	-.18342	.0397653	-4.61	0.000	-.2613586	-.1054814
dlp_ftse100						
L1.	.0134614	.0354126	0.38	0.704	-.0559459	.0828687
L2.	.0429501	.0517527	0.83	0.407	-.0584833	.1443834
L3.	.0512604	.0607139	0.84	0.399	-.0677367	.1702576
L4.	-.0185	.0635007	-0.29	0.771	-.142959	.105959
L5.	.0089758	.0603012	0.15	0.882	-.1092124	.1271639
L6.	.0875219	.0510837	1.71	0.087	-.0126002	.1876441
L7.	.0174635	.0339423	0.51	0.607	-.0490622	.0839891
dlp_crobex						
L1.	.1483071	.0461051	3.22	0.001	.0579428	.2386715
L2.	.1223703	.0607622	2.01	0.044	.0032786	.2414619
L3.	.0840538	.0685977	1.23	0.220	-.0503952	.2185028
L4.	.0577839	.0717284	0.81	0.420	-.0828013	.1983691
L5.	.0757628	.0682966	1.11	0.267	-.0580961	.2096217
L6.	.0524338	.0601543	0.87	0.383	-.0654665	.1703341
L7.	-.0212477	.0458092	-0.46	0.643	-.111032	.0685367
_cons	-.0000178	.0002597	-0.07	0.945	-.0005267	.0004911

dlp_ftse100						
dlp_sp500						
L1.	.4047228	.0410921	9.85	0.000	.3241837	.4852618
L2.	.4240208	.0626584	6.77	0.000	.3012126	.5468291
L3.	.3586633	.075427	4.76	0.000	.2108291	.5064976
L4.	.285105	.0798671	3.57	0.000	.1285684	.4416416
L5.	.2058913	.0761001	2.71	0.007	.056738	.3550447
L6.	.0470402	.0643396	0.73	0.465	-.079063	.1731435
L7.	-.0385152	.0428997	-0.90	0.369	-.122597	.0455666
dlp_ftse100						
L1.	-1.106149	.0382038	-28.95	0.000	-1.181027	-1.031271
L2.	-1.030601	.0558319	-18.46	0.000	-1.140029	-.9211721
L3.	-.8565281	.0654995	-13.08	0.000	-.9849048	-.7281515
L4.	-.7219352	.0685059	-10.54	0.000	-.8562042	-.5876662
L5.	-.5512399	.0650542	-8.47	0.000	-.6787437	-.423736
L6.	-.2645103	.0551101	-4.80	0.000	-.3725242	-.1564964
L7.	-.1253958	.0366176	-3.42	0.001	-.197165	-.0536266
dlp_crobex						
L1.	-.0059783	.0497392	-0.12	0.904	-.1034653	.0915087
L2.	.016918	.0655515	0.26	0.796	-.1115606	.1453966
L3.	-.0658877	.0740047	-0.89	0.373	-.2109341	.0791588
L4.	-.0763221	.0773822	-0.99	0.324	-.2279884	.0753441
L5.	-.0196878	.0736798	-0.27	0.789	-.1640977	.124722
L6.	-.0026563	.0648958	-0.04	0.967	-.1298496	.1245371
L7.	.0115359	.0494199	0.23	0.815	-.0853253	.1083972
_cons	.0000107	.0002801	0.04	0.969	-.0005383	.0005597

dlp_crobex						
dlp_sp500						
L1.	.1195607	.0245807	4.86	0.000	.0713835	.167738
L2.	.1894729	.0374813	5.06	0.000	.1160109	.2629349
L3.	.1471129	.0451193	3.26	0.001	.0586807	.235545
L4.	.0859341	.0477753	1.80	0.072	-.0077038	.1795719
L5.	.0452323	.0455219	0.99	0.320	-.0439889	.1344536
L6.	.0271118	.0384869	0.70	0.481	-.0483212	.1025449
L7.	-.0037726	.0256619	-0.15	0.883	-.0540691	.0465239
dlp_ftse100						
L1.	-.0410628	.0228529	-1.80	0.072	-.0858537	.0037282
L2.	-.0885029	.0333978	-2.65	0.008	-.1539614	-.0230445
L3.	-.0539384	.0391808	-1.38	0.169	-.1307313	.0228545
L4.	-.0459729	.0409792	-1.12	0.262	-.1262906	.0343447
L5.	-.0085895	.0389144	-0.22	0.825	-.0848604	.0676813
L6.	.0160962	.032966	0.49	0.625	-.0485161	.0807085
L7.	.0093909	.0219041	0.43	0.668	-.0335404	.0523221
dlp_crobex						
L1.	-.8576694	.0297532	-28.83	0.000	-.9159846	-.7993541
L2.	-.737563	.0392119	-18.81	0.000	-.814417	-.6607091
L3.	-.6336894	.0442684	-14.31	0.000	-.720454	-.5469249
L4.	-.4489218	.0462888	-9.70	0.000	-.5396463	-.3581974
L5.	-.2978611	.0440741	-6.76	0.000	-.3842449	-.2114774
L6.	-.1921255	.0388196	-4.95	0.000	-.2682107	-.1160404
L7.	-.1167621	.0295622	-3.95	0.000	-.174703	-.0588212
_cons	.0000171	.0001676	0.10	0.919	-.0003113	.0003455

Prije nego se pristupi interpretaciji rezultata, a nakon procjene parametara prema Bahovec i Erjavec (2009), potrebno je provesti analizu primjerenosti modela. Potrebno je analizirati rezidualna odstupanja te provjeriti korelograme, autokoreliranost, normalnost itd. Navedeni testovi koje treba provesti redom su uneseni u *odziv.do* datoteku kako bi ih bilo lakše izvoditi nakon svake VAR analize. Spomenuta .do datoteka sadrži sljedeće naredbe:

```
varstable
varlmar
varlmar, mlag(15)
varnorm, jbera
vargranger
matrix s=e(Sigma)
matrix list s
matrix l=cholesky(s)
matrix list l
irf set "myirf1.irf"
irfcreate order1, step(20) set(myirf1,replace)

irf table oirf, irf(order1)
irfgraphoirf, irf(order1)
```

Funkcija *varstable* provjerava je li testirani model stabilan.

```
. varstable

Eigenvalue stability condition
```

Eigenvalue	Modulus
.5105983 + .6456491*i*	.823148
.5105983 - .6456491*i*	.823148
-.1601801 + .7985602*i*	.814467
-.1601801 - .7985602*i*	.814467
.446969 + .6395924*i*	.780295
.446969 - .6395924*i*	.780295
-.7736347	.773635
-.5327317 + .5603567*i*	.773177
-.5327317 - .5603567*i*	.773177
-.7614562	.761456
.4899929 + .5676184*i*	.749856
.4899929 - .5676184*i*	.749856
.03237636 + .7288924*i*	.729611
.03237636 - .7288924*i*	.729611
-.04240181 + .7255207*i*	.726759
-.04240181 - .7255207*i*	.726759
-.5759507 + .4309299*i*	.719319
-.5759507 - .4309299*i*	.719319
-.5014615 + .5107229*i*	.715752
-.5014615 - .5107229*i*	.715752
-.6752659	.675266

```
All the eigenvalues lie inside the unit circle.
VAR satisfies stability condition.
```

Rezultati ukazuju na to da sve vrijednosti leže unutar jediničnog kruga, što znači da je VAR model stabilan. Isto se može vidjeti i na priloženom grafičkom prikazu.

Grafički prikaz 15 Rezultati stabilnosti modela

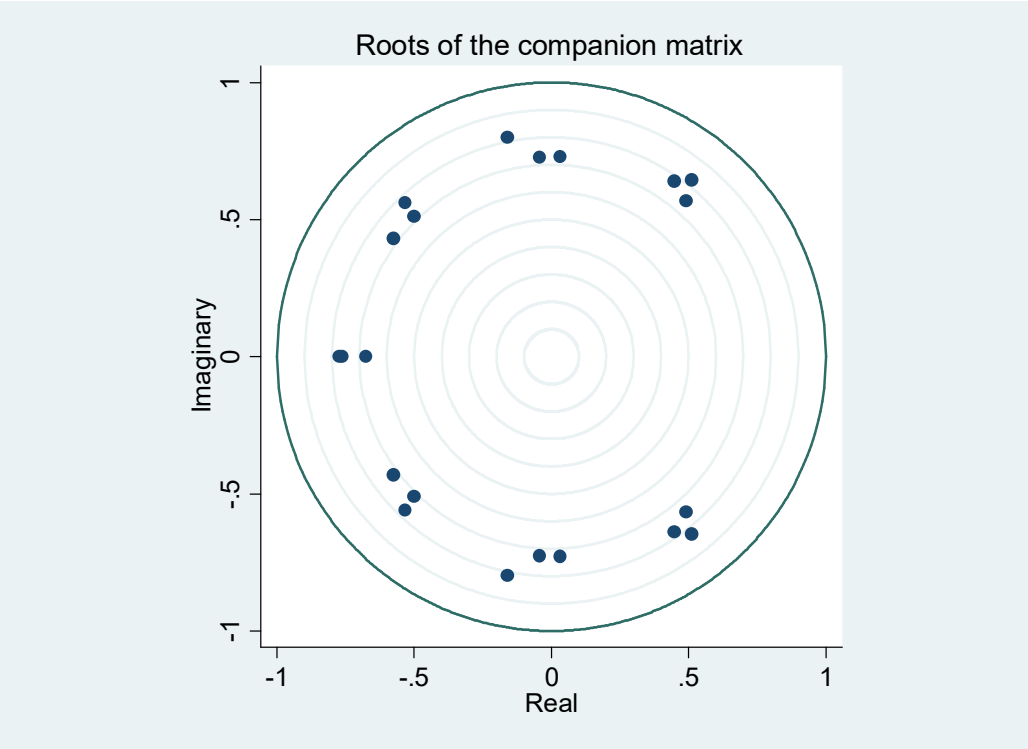

Izvor: Izrada autora

Varlmar funkcija provjerava postoji li autokorelacija reziduala modela.

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	33.7971	9	0.00010
2	59.6962	9	0.00000

H0: no autocorrelation at lag order

H0: Hipoteza pretpostavlja da autokorelacija ne postoji, ali prema rezultatima testa odbacujemo ovu hipotezu (0,00<0,05) te zaključujemo da na razini prvog i drugog odmaka autokorelacija postoji. Autokorelacija predstavlja potencijalni problem u interpretaciji rezultata te stoga provodimo detaljniju analizu autokorelacija do maksimalnog pomaka od 15 radnih dana. Autokorelacija u VAR modelu s ovako velikim brojem pomaka (7) nije neočekivana jer u

vremenskim nizovima postoje različiti utjecaji jedne opservacije na sljedeće. Stoga se ovaj problem može donekle zanemariti. Na sljedećem prikazu možemo uočiti kako autokorelacija postoji u prvih 8 pomaka testiranog VAR modela.

```
. varlmar, mlag(15)
```

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	33.7971	9	0.00010
2	59.6962	9	0.00000
3	101.7227	9	0.00000
4	118.2979	9	0.00000
5	144.8181	9	0.00000
6	141.7730	9	0.00000
7	157.1577	9	0.00000
8	152.0633	9	0.00000
9	5.5170	9	0.78711
10	9.3727	9	0.40361
11	6.1368	9	0.72616
12	9.5889	9	0.38478
13	13.3609	9	0.14694
14	15.1885	9	0.08589
15	8.6764	9	0.46766

H0: no autocorrelation at lag order

H0 hipoteza Jarque-Bera testa pretpostavlja normalnu distribuciju. Prema rezultatima Jarque-Bera testa H0 hipotezu odbacujemo(0,00<0,05) te zaključujemo da reziduali modela nisu normalno distribuirani.

```
. varnorm, jbera
```

Jarque-Bera test

Equation	chi2	df	Prob > chi2
dlp_sp500	280.545	2	0.00000
dlp_ftse100	496.981	2	0.00000
dlp_crobex	115.277	2	0.00000
ALL	892.804	6	0.00000

Prema gore navedenom, prilikom interpretacije rezultata promatrat će se skupni utjecaj jednog vremenskog niza na drugi, tj. utjecaj jednog indeksa na drugi indeks, te se neće interpretirati procijenjeni koeficijenti svakog dana posebno jer rezultati nisu dovoljno pouzdani za takvu analizu. Potrebno je stoga istražiti postoji li uzročnost u jednom smjeru ili u oba smjera za svaki par indeksa iz ocijenjenog VAR modela. Grangerov test koji slijedi namijenjen je testiraju spomenute uzročnosti jednoga niza na drugi.

```
. vargranger

Granger causality Wald tests
```

Equation	Excluded	chi2	df	Prob > chi2
dlp_sp500	dlp_ftse100	15.422	7	0.031
dlp_sp500	dlp_crobex	13.344	7	0.064
dlp_sp500	ALL	30.932	14	0.006
dlp_ftse100	dlp_sp500	110.52	7	0.000
dlp_ftse100	dlp_crobex	3.9917	7	0.781
dlp_ftse100	ALL	118.28	14	0.000
dlp_crobex	dlp_sp500	33.543	7	0.000
dlp_crobex	dlp_ftse100	11.992	7	0.101
dlp_crobex	ALL	43.11	14	0.000

Rezultati Grangerovog testa uzročnosti ukazuju na to da S&P500 indeks ima statistički značajan utjecaj na CROBEX indeks i na FTSE100 indeks. Utjecaj FTSE100 indeksa na S&P500 indeks je također statistički značajan. Prema tome možemo reći da između FTSE100 i S&P500 indeksa postoji uzročnost u oba smjera, što znači da ta dva indeksa međusobno utječu jedan na drugi. Ovakav zaključaj je u skladu s ekonomskom teorijom i dosadašnjim empirijskim istraživanjima.

S obzirom na to da je CROBEX indeks u fokusu ovoga istraživanja, važno je napomenuti kako Grangerov test uzročnosti pokazuje statistički značajan utjecaj S&P500 indeksa na CROBEX, dok utjecaj FTSE100 na CROBEX nije statistički značajan. Dakle, može se zaključiti da indeks NYSE (New York Stock Exchange) ima veći utjecaj na kretanje CROBEX indeksa nego indeks Londonske burze. Slični su se rezultati pojavljivali i u ranijim istraživanjima.

Naposljetku provodimo dekompoziciju varijance i utjecaj šoka od jedna standardne devijacije, takozvani test impulsnog odziva. Rezultati testa impulsnog odziva prikazani su na sljedećeg grafičkom prikazu za sve parove varijabli Modela A.

Grafički prikaz 16 Rezultati impulsnog odziva Modela A

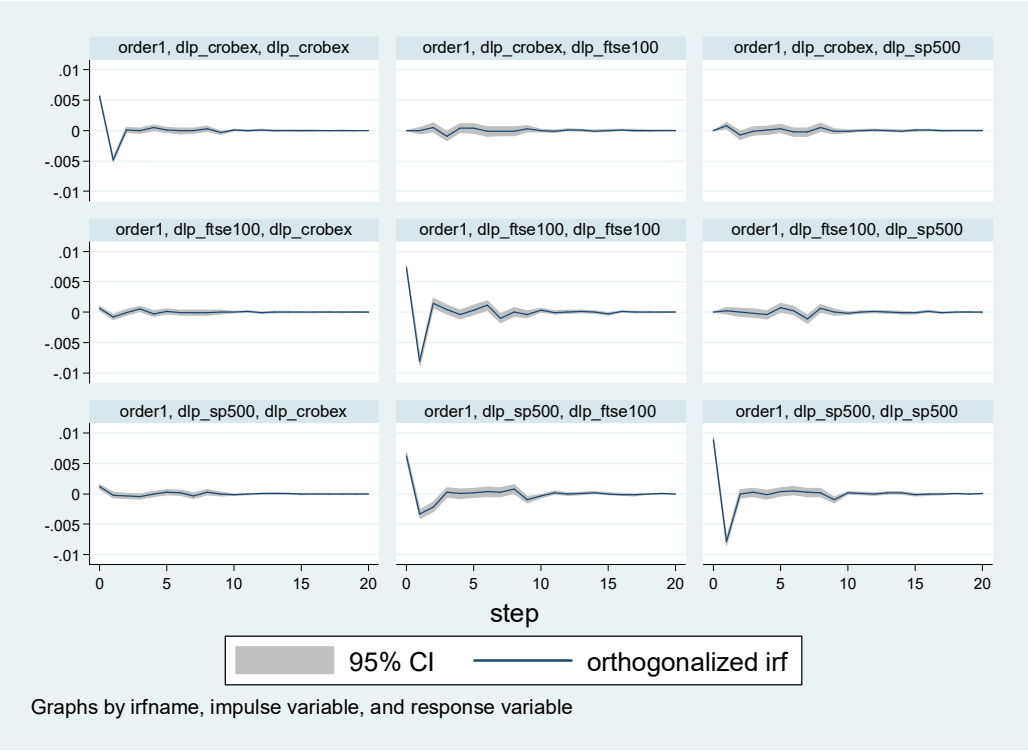

Izvor: Izrada autora

Iz navedenog grafa možemo vidjeti kako sva tri indeksa imaju snažan utjecaj na grafovima prikazanim na dijagonali, tj. ti grafovi prikazuju kakav je utjecaj šoka u tom indeksu na kasnije vrijednosti toga indeksa. Vrlo je očito da sva tri indeksa reagiraju vrlo slično. Nakon promjene u razdoblju 0, dolazi do značajnog pada u razdoblju 1, a nakon toga se vrijednost indeksa stabilizira i početna promjena nema značajnih utjecaja na kasnije vrijednosti.

Rezultati pokazuju kako spomenuti utjecaj vrijedi i za CROBEX indeks. Dakle, nakon šoka u razdoblju 0, vrijednost indeksa u razdoblju 1 će pasti, a zatim se stabilizirati. Pozitivan šok u vrijednosti FTSE100 indeksa utjecat će na malu pozitivnu promjenu indeksa CROBEX u razdoblju 0, dok će u razdoblju 1 uslijediti također vrlo mala negativna promjena. Nakon toga se vrijednost indeksa CROBEX stabilizira. Treći graf u prvom stupcu prikazuje da će pozitivan šok u vrijednosti S&P500 indeksa utjecati na mali pozitivan šok u vrijednosti CROBEX indeksa, a nakon toga će se vrijednost CROBEX indeksa stabilizirati. Iako utjecaj između S&P500 i FTSE100 indeksa nije u središtu ovoga istraživanja, zanimljivo je za primijetiti da bi porast

S&P500 indeksa imao pozitivan utjecaj na FTSE100 indeks u 0 razdoblju, te značajan negativan utjecaj u prvom i drugom razdoblju, nakon čega se vrijednost indeksa stabilizira. Također na grafovima u prvom redu možemo vidjeti kako šok pozitivne promjene u vrijednosti CROBEX indeksa nema značajan utjecaj na FTSE100 ili na S&P500. Takav utjecaj naravno nije niti bio očekivan.

Nakon analize VAR modela B bit će prikazani rezultati VAR modela B. Očekuje se da će rezultati biti približno slični, zbog slične strukture modela, te visoke korelacije između parova američkih i engleskih indeksa. Rezultati VAR modela **Model B**:

```
. var dlp_dji dlp_dax dlp_crobex, lags(1/7)

Vector autoregression

Sample:  10 - 1184                                  No. of obs      =      1175
Log likelihood =  12103.43                          AIC             = -20.48923
FPE            =  2.54e-13                          HQIC            = -20.38187
Det(Sigma_ml)  =  2.27e-13                          SBIC            = -20.20451

Equation           Parms      RMSE     R-sq      chi2     P>chi2
----------------------------------------------------------------
dlp_dji              22     .008569   0.4742   1059.711   0.0000
dlp_dax              22     .012939   0.4646   1019.583   0.0000
dlp_crobex           22     .005811   0.4307   889.1035   0.0000
----------------------------------------------------------------

------------------------------------------------------------------------------
             |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
dlp_dji      |
     dlp_dji |
         L1. |  -.9346871   .0366958   -25.47   0.000     -1.00661   -.8627646
         L2. |  -.8584245   .0533549   -16.09   0.000    -.9629981   -.7538509
         L3. |  -.7246683   .0627818   -11.54   0.000    -.8477183   -.6016183
         L4. |  -.5989502   .0657614    -9.11   0.000    -.7278402   -.4700603
         L5. |  -.4772678   .0630767    -7.57   0.000    -.6008959   -.3536397
         L6. |  -.3931998   .0540045    -7.28   0.000    -.4990468   -.2873529
         L7. |  -.1989901   .0373351    -5.33   0.000    -.2721656   -.1258146
             |
     dlp_dax |
         L1. |   .0115141   .0245408     0.47   0.639    -.0365849    .0596131
         L2. |   .0465597   .0340832     1.37   0.172    -.0202422    .1133616
         L3. |   .0483722   .0388696     1.24   0.213    -.0278109    .1245553
         L4. |   .0123707   .0406318     0.30   0.761    -.0672662    .0920076
         L5. |    .010512   .0388249     0.27   0.787    -.0655834    .0866074
         L6. |   .0723114   .0338988     2.13   0.033      .005871    .1387517
         L7. |   .0253184   .0240092     1.05   0.292    -.0217387    .0723755
             |
  dlp_crobex |
         L1. |   .1220009    .044161     2.76   0.006     .0354468    .2085549
         L2. |   .0826267   .0581375     1.42   0.155    -.0313207     .196574
         L3. |   .0468069    .065596     0.71   0.475     -.081759    .1753728
         L4. |   .0134971   .0684707     0.20   0.844     -.120703    .1476973
         L5. |   .0341109   .0651596     0.52   0.601    -.0935997    .1618214
         L6. |   .0222103   .0575091     0.39   0.699    -.0905056    .1349261
         L7. |  -.0205136   .0437881    -0.47   0.639    -.1063366    .0653094
             |
       _cons |  -.0000113   .0002476    -0.05   0.964    -.0004966    .0004741
------------------------------------------------------------------------------
```

dlp_dax						
dlp_dji						
L1.	.3406301	.0554131	6.15	0.000	.2320224	.4492377
L2.	.2898927	.0805694	3.60	0.000	.1319797	.4478058
L3.	.2017705	.0948046	2.13	0.033	.0159568	.3875842
L4.	.1124358	.0993041	1.13	0.258	-.0821966	.3070682
L5.	.0513372	.09525	0.54	0.590	-.1353494	.2380239
L6.	-.0928764	.0815504	-1.14	0.255	-.2527123	.0669595
L7.	-.0885949	.0563785	-1.57	0.116	-.1990947	.021905
dlp_dax						
L1.	-.9948365	.0370582	-26.85	0.000	-1.067469	-.9222038
L2.	-.8668967	.0514679	-16.84	0.000	-.967772	-.7660214
L3.	-.7295994	.0586957	-12.43	0.000	-.8446409	-.6145579
L4.	-.5951594	.0613567	-9.70	0.000	-.7154164	-.4749024
L5.	-.4793491	.0586282	-8.18	0.000	-.5942582	-.36444
L6.	-.2276411	.0511894	-4.45	0.000	-.3279705	-.1273118
L7.	-.1079829	.0362554	-2.98	0.003	-.1790422	-.0369235
dlp_crobex						
L1.	-.0285377	.0666861	-0.43	0.669	-.1592401	.1021647
L2.	.0460148	.0877914	0.52	0.600	-.1260532	.2180829
L3.	.0276918	.0990544	0.28	0.780	-.1664512	.2218348
L4.	-.0218316	.1033953	-0.21	0.833	-.2244827	.1808195
L5.	.0595952	.0983954	0.61	0.545	-.1332562	.2524466
L6.	.0739028	.0868426	0.85	0.395	-.0963055	.2441112
L7.	.0426766	.0661229	0.65	0.519	-.0869218	.172275
_cons	-.0000266	.0003739	-0.07	0.943	-.0007595	.0007063

dlp_crobex						
dlp_dji						
L1.	.1104587	.0248849	4.44	0.000	.0616851	.1592323
L2.	.1698454	.0361821	4.69	0.000	.0989297	.2407611
L3.	.139911	.0425749	3.29	0.001	.0564656	.2233563
L4.	.0778625	.0445955	1.75	0.081	-.0095431	.1652681
L5.	.0327621	.0427749	0.77	0.444	-.0510753	.1165994
L6.	.0159984	.0366227	0.44	0.662	-.0557808	.0877776
L7.	-.0122387	.0253185	-0.48	0.629	-.061862	.0373847
dlp_dax						
L1.	-.0136746	.0166421	-0.82	0.411	-.0462925	.0189434
L2.	-.045567	.0231132	-1.97	0.049	-.0908681	-.0002658
L3.	-.0354588	.0263591	-1.35	0.179	-.0871217	.0162041
L4.	-.0222197	.0275541	-0.81	0.420	-.0762248	.0317853
L5.	.0010121	.0263288	0.04	0.969	-.0505913	.0526156
L6.	.0183033	.0229882	0.80	0.426	-.0267527	.0633592
L7.	.0147239	.0162816	0.90	0.366	-.0171875	.0466352
dlp_crobex						
L1.	-.8625858	.0299474	-28.80	0.000	-.9212817	-.8038899
L2.	-.7372473	.0394254	-18.70	0.000	-.8145198	-.6599749
L3.	-.6279467	.0444834	-14.12	0.000	-.7151325	-.5407608
L4.	-.4454595	.0464328	-9.59	0.000	-.5364662	-.3544528
L5.	-.2888668	.0441875	-6.54	0.000	-.3754726	-.2022609
L6.	-.1867225	.0389993	-4.79	0.000	-.2631598	-.1102853
L7.	-.1130043	.0296945	-3.81	0.000	-.1712044	-.0548042
_cons	.0000149	.0001679	0.09	0.929	-.0003142	.0003441

Nakon procjene parametara VAR modela Model B, provodi se testiranje primjerenosti modela, analogno Modelu A.

```
. varstable

Eigenvalue stability condition
```

Eigenvalue	Modulus
.5114798 + .6487909i	.826161
.5114798 - .6487909i	.826161
-.1462916 + .792731i	.806116
-.1462916 - .792731i	.806116
.5209576 + .5934053i	.789637
.5209576 - .5934053i	.789637
-.7649092 + .00706487i	.764942
-.7649092 - .00706487i	.764942
-.5409257 + .5395404i	.764005
-.5409257 - .5395404i	.764005
.00139365 + .751826i	.751827
.00139365 - .751826i	.751827
.440721 + .592627i	.73854
.440721 - .592627i	.73854
-.5567861 + .4545656i	.718777
-.5567861 - .4545656i	.718777
-.02293479 + .704013i	.704386
-.02293479 - .704013i	.704386
-.4983684 + .4966966i	.703618
-.4983684 - .4966966i	.703618
-.680782	.680782

```
All the eigenvalues lie inside the unit circle.
VAR satisfies stability condition.
```

Rezultati ukazuju na to da je Model B također stabilan.

```
. varlmar, mlag(15)

Lagrange-multiplier test
```

lag	chi2	df	Prob > chi2
1	30.6760	9	0.00034
2	59.7810	9	0.00000
3	99.3291	9	0.00000
4	120.0217	9	0.00000
5	150.4762	9	0.00000
6	144.1255	9	0.00000
7	161.1687	9	0.00000
8	149.7353	9	0.00000
9	6.1977	9	0.71998
10	6.5968	9	0.67902
11	8.2468	9	0.50948
12	14.1487	9	0.11713
13	10.4977	9	0.31171
14	22.3089	9	0.00795
15	8.8357	9	0.45258

```
H0: no autocorrelation at lag order
```

Analogno Modelu A, u Modelu B se pojavljuje problem autokorelacije.

```
. varnorm, jbera

Jarque-Bera test
```

Equation	chi2	df	Prob > chi2
dlp_dji	286.190	2	0.00000
dlp_dax	430.473	2	0.00000
dlp_crobex	110.695	2	0.00000
ALL	827.358	6	0.00000

Analogno Modelu A, Model B ne zadovoljava uvjet normalne distribucije reziduala.

```
. vargranger

Granger causality Wald tests
```

Equation	Excluded	chi2	df	Prob > chi2
dlp_dji	dlp_dax	14.785	7	0.039
dlp_dji	dlp_crobex	9.9469	7	0.192
dlp_dji	ALL	27.442	14	0.017
dlp_dax	dlp_dji	49.007	7	0.000
dlp_dax	dlp_crobex	3.698	7	0.814
dlp_dax	ALL	54.878	14	0.000
dlp_crobex	dlp_dji	28.538	7	0.000
dlp_crobex	dlp_dax	7.7534	7	0.355
dlp_crobex	ALL	37.755	14	0.001

Rezultati Grangerovog testa uzročnosti u Modelu B također su vrlo očekivani i vrlo slični rezultatima Modela A. Rezultati Modela B ukazuju na to da DJI indeks ima statistički značajan utjecaj na CROBEX indeks i na DAX indeks. Utjecaj DAX indeksa na DJI indeks je također statistički značajan. Prema tome možemo reći da između DAX i DJI indeksa postoji uzročnost u oba smjera, što znači da ta dva indeksa međusobno utječu jedan na drugi.

Kao i u prijašnjem modelu, važno je napomenuti kako Grangerov test uzročnosti pokazuje statistički značajan utjecaj DJI indeksa na CROBEX, dok utjecaj DAX indeksa na CROBEX nije statistički značajan. Dakle, može se zaključiti da DJI indeks ima veći utjecaj na kretanje CROBEX indeksa nego DAX indeks. Zaključak je analogan zaključku Modela A.

Rezultati testa impulsnog odziva prikazani su na sljedećeg grafičkom prikazu za sve parove varijabli Modela B.

Grafički prikaz 17 Rezultati impulsnog odziva Modela B

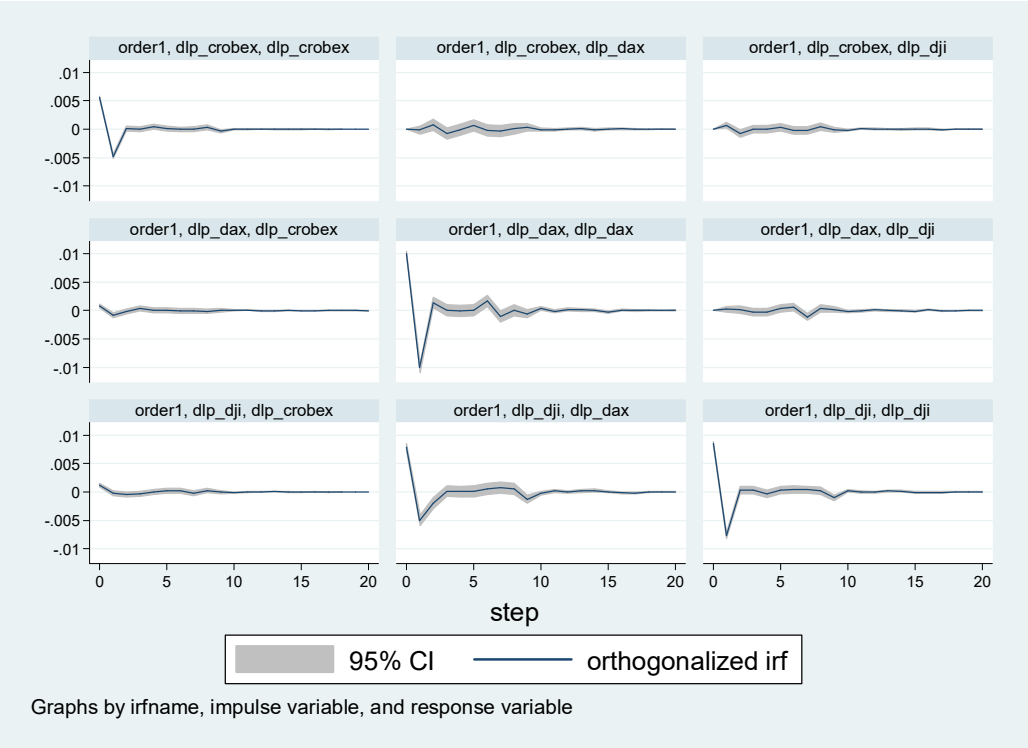

Izvor: Izrada autora

Prema rezultatima impulsnog odziva Modela B, analogno Modelu A, iz navedenog grafa može se vidjeti kako sva tri indeksa imaju snažan utjecaj na grafovima prikazanim na dijagonali, tj. imaju utjecaj na vrijednost istoga indeksa u kasnijim razdobljima. Vrlo je očito da sva tri indeksa reagiraju vrlo slično. Nakon promjene u razdoblju 0, dokazi do značajnog pada u razdoblju 1, a nakon toga se vrijednost indeksa stabilizira i početna promjena nema značajnih utjecaja na kasnije vrijednosti.

Rezultati pokazuju kako spomenuti utjecaj vrijedi i za CROBEX indeks. Dakle, nakon šoka u razdoblju 0, vrijednost indeksa u razdoblju 1 će pasti, a zatim se stabilizirati. Pozitivan šok u vrijednosti DAX indeksa će utjecati na malu pozitivnu promjenu indeks CROBEX u razdoblju 0, dok će u razdoblju 1 uslijediti također vrlo mala negativna promjena. Nakon toga se vrijednost indeksa CROBEX stabilizira. Treći graf u prvom stupcu prikazuje da će pozitivan šok u vrijednosti DJI indeksa utjecati na mali pozitivan šok u vrijednosti CROBEX indeksa, a nakon toga će se vrijednost CROBEX indeksa stabilizirati. Iako utjecaj između DJI i DAX indeksa nije

u središtu ovoga istraživanja, zanimljivo je za primijetiti da bi porast DJI indeksa imao pozitivan utjecaj na DAX indeks u 0 razdoblju te značajan negativan utjecaj u prvom i drugom razdoblju, nakon čega se vrijednost indeksa stabilizira. Također na grafovima u prvom redu možemo vidjeti kako šok pozitivne promjene u vrijednosti CROBEX indeksa nema značajan utjecaj na DAX ili na DJI indeks. Može se primijetiti da su rezultati Modela B gotovo identični rezultatima Modela A, što je i očekivano zbog vrlo visokog stupnja korelacije između spomenutih parova indeksa.

Rezultati ovoga istraživanja odgovaraju zaključcima ranije spomenutih istraživanja. Primjerice, Friedman i Shachmurove (1997) uočavaju visok stupanj korelacije između europskih tržišta kapitala koji je uočen i u ovom istraživanju između FTSE100 indeksa i DAX indeksa. Uzročnost u oba smjera između S&P500 indeksa i FTSE100 potvrđuje rezultate Morana i Beltratti (2008) koji uočavaju jaku vezu između tržišta kapitala u SAD-u i u Ujedinjenom Kraljevstvu. Rezultati ovoga istraživanja su također u skladu sa zaključkom Tomić, Sesar i Džaja (2014) koji tvrde da DJIA dobro predviđa kretanja na europskom tržištu kapitala. Olbrys i Majewska (2014) potvrđuju utjecaj američke krize 2007. Na CEE kapitalna tržišta, a rezultati ovoga istraživanja pokazuju kako je američko tržište utjecalo na hrvatsko tržište kapitala i nakon krize. S druge strane, rezultati ovoga istraživanja nisu u skladu s zaključkom Białkowski, Bohl i Serwa (2006) koji odbijaju hipotezu utjecaja američkog tržišta na ostala kapitalna tržišta.

Analizirajući samo hrvatsko i njemačko tržište kapitala Vizek i Dadić (2006) ne pronalaze dokaze o bilateralnoj integraciji u razdoblju od 1997. do 2005. Prema rezultatima ovoga istraživanja možemo donijeti isti zaključak i nakon krize. Erjavec i Cota (2007) u razdoblju od 2000. do 2004. pronalaze utjecaju europskih DAX i FTSE100 indeksa na CROBEX unutar istog dana trgovanja i utjecaj američkih indeksa DJIA i NASDAQ s odmakom od jednog dana trgovanja. Dodatno, tvrde kako vrijednost CROBEX indeksa s jednim danom odmaka (unutarnja veza) ne utječe na kretanje CROBEX indeksa danas. Posljednji zaključak nije u skalu s rezultatima ovoga istraživanja koji upućuju na to da prethodne vrijednosti CROBEX-a imaju statistički značaja utjecaj. Sajter i Ćorić (2009) tvrde kako u kratkom roku na kretanje hrvatskog tržišta kapitala najviše utječu psihološki faktori. Iako su direktne veze hrvatskog i američkog tržišta vrlo slabe, investitori se značajno oslanjaju na informacije s američkog tržišta. Ovaj zaključak temelji se na rezultatima istraživanja provedenog na podacima od 2005. do 2008.

godine čime je razdoblje krize obuhvaćeno samo djelomično. Rezultati ovoga istraživanja na podacima u razdoblju od 2012. do 2016. godine također pokazuju postojanje utjecaja američkog tržišta na hrvatsko kapitalno tržište.

Ako usporedimo rezultate ovoga istraživanja i zaključke ranijih istraživanja možemo zaključiti da se ponašanje investitora na hrvatskom tržištu kapitala nije značajno promijenilo u odnosu na razdoblje prije krize te da je utjecaj informacija s američkog tržišta još uvijek vrlo snažan.

Nakon prezentiranih rezultata istraživanja možemo donijeti i konačne zaključke o pomoćnim hipotezama postavljenim na početku ovoga istraživanja.

- Prihvaćamo H1a: Postoji utjecaj kretanja S&P500 indeksa na kretanje indeksa CROBEX.
- Prihvaćamo H1b: Postoji utjecaj kretanja DJI indeksa na kretanje indeksa CROBEX.
- Odbacujemo H1c: Postoji utjecaj kretanja FTSE100 indeksa na kretanje indeksa CROBEX.
- Odbacujemo H1d: Postoji utjecaj kretanja DAX indeksa na kretanje indeksa CROBEX.

Prema tome, treba donijeti sud i o temeljnoj hipotezi ovoga istraživanja.

- Prihvaćamo H1: Postoji utjecaj kretanja stranih tržišta kapitala na kretanja hrvatskog tržišta kapitala.

Unatoč tome što smo odbacili pomoćne hipoteze H1c i H1d, jer nije pronađen statistički značajan utjecaj europskih indeksa na kretanje CROBEX indeksa, prihvaćamo H1 hipotezu da postoji utjecaj kretanja stranih tržišta kapitala na kretanje hrvatskog tržišta kapitala. U ovome radu pokazano je da H1a postoji utjecaj kretanja S&P500 indeksa na kretanje CROBEX indeksa te da H1b postoji utjecaj kretanja DJI indeksa na kretanje CROBEX indeksa. Općenito govoreći možemo reći da postoji značajan utjecaj informacija s američkog tržišta kapitala na hrvatsko tržište kapitala.

6. ZAKLJUČAK

U ovom radu prezentirani su radovi na temu financijskog prelijevanja između velikih razvijenih svjetskih kapitalnih tržišta te isto tako i radovi u kojima se ispituje utjecaj spomenutoga prelijevanja na tržišta u razvoju kao što je i hrvatsko.

Predmet ovoga istraživanja predstavlja utvrđivanje kratkoročnih utjecaja američkih S&P500 i DJI tržišnih indeksa i europskih DAX i FTSE100 indeksa na hrvatski indeks tržišta kapitala, CROBEX.

Teorijski dio rada sastoji se od pregleda dosadašnje literature o međuovisnosti kapitalnih tržišta. Posebna pozornost posvećena je utjecaju koji informacije sa stranih tržišta kapitala imaju na hrvatsko tržište kapitala.

Empirijski dio rada prikazuje rezultate vektorskih autoregresijskih modela (VAR modela) koji temeljeni na dnevnim podacima ocjenjuju međuodnose i utjecaj američkih indeksa S&P500 i DJI te europskih indeksa DAX i FTSE100 na hrvatski CROBEX indeks. Istraživanje obuhvaća dnevne podatke o zaključnim vrijednostima indeksa u poslijekriznom razdoblju od 1.1.2012. do 31.12.2016., kako bi se utvrdilo jesu li obrasci međuovisnosti kretanja indeksa zabilježeni u znanstvenim radovima prije krize (Vizek i Dadić 2006; Erjavec i Cota 2007; Sajter i Ćorić 2009) zadržali svoje karakteristike.

Rezultati su pokazali postojanje značajnog utjecaj kretanja S&P500 indeksa na kretanje CROBEX indeksa te da postoji utjecaj kretanja DJI indeksa na kretanje CROBEX indeksa. Općenito govoreći možemo reći da postoji značajan utjecaj informacija s američkog tržišta kapitala na hrvatsko tržište kapitala. Utjecaji europskih kapitalnih tržišta nisu pokazali dovoljno značajne utjecaje na hrvatsko kapitalno tržište.

Ako usporedimo rezultate ovoga istraživanja i zaključke ranijih istraživanja možemo zaključiti da se ponašanje investitora na hrvatskom tržištu kapitala nije značajno promijenilo u odnosu na razdoblje prije krize te da je utjecaj informacija s američkog tržišta još uvijek vrlo snažan.

Svakako je potrebno komentirati činjenicu da američko tržište kapitala ima značajniji utjecaj negoli europska kapitalna tržišta na hrvatsko kapitalno tržište. Ova pojava je pomalo nelogično s obzirom na to da Hrvatska ima mnogo snažnije ekonomske odnose s europskim zemljama nego s Amerikom. Ipak, pokazalo se kako investitori na hrvatskom tržištu kapitala informacijama s europskih kapitalnih tržišta pridaju manji značaj. Rezultati ovoga istraživanja su u skladu sa zaključkom Sajter i Ćorić (2009) koji tvrde kako u kratkom roku na kretanje hrvatskog tržišta kapitala najviše utječu psihološki faktori.

Postavlja se pitanje kako zaključci ovoga istraživanja mogu doprinijeti kvalitetnijim investicijskim odlukama investitora na hrvatskom tržištu kapitala. Hrvatsko tržište kapitala dakle prati kretanja na američkom tržištu kapitala u kratkom roku. Prema tome, investitori mogu koristiti informacije sa stranih tržišta u predviđanju kretanja na hrvatskom kapitalnom tržištu. Prema rezultatima ovoga istraživanja vidljivo je da je u kratkom roku utjecaj američkog tržišta na hrvatsko vrlo značajan, ipak problem predstavljaju relativno visoki transakcijski troškovi zbog kojih se trgovanje u kratkom roku na hrvatskom tržištu kapitala možda ne isplati. Naravno, na investitorima je da donesu konačnu odluku o svojim ulaganjima.

7. LITERATURA

Knjige:

1. Bahovec, Vlasta, i Nataša Erjavec. 2009. *Introduction to EconometricAnalysis*. Element. http://bib.irb.hr/prikazi-rad?rad=758922.

Članci i studije:

1. Benazić, Manuel. 2008. „Povezanost cijene dionica i deviznog tečaja u Republici Hrvatskoj: VEC model“. *Ekonomski pregled* 59 (11): 669–87.
2. Białkowski, Jędrzej, Martin T. Bohl, i Dobromił Serwa. 2006. „Testing for financial spillovers in calm and turbulent periods“. *The Quarterly Review of Economics and Finance*, Real and Financial Aspects of Financial IntegrationPapers drawn from the 3rd INFINITI conference on International Financial Integration, held at the Institute for International Integration Studies, Trinity College, Dublin, June 2005The 3rd INFINITI conference on International Financial Integration, 46 (3): 397–412. doi:10.1016/j.qref.2006.04.001.
3. Dabić, Stanko, i Stipan Penavin. 2009. „Utjecaj obujma trgovanja na kretanje tržišnog indeksa Crobex“. *Ekonomski Vjesnik/Econviews: Review of contemporary business, entrepreneurship and economic issues* 22 (1): 51–61.
4. Dalić, Martina. 2002. „USPOREDNA ANALIZA HRVATSKOG FINANCIJSKOG SUSTAVA I FINANCIJSKIH SUSTAVA NAPREDNIH TRANZICIJSKIH ZEMALJA“. *Privredna kretanja i ekonomska politika* 12 (92): 27–52.
5. Erjavec, Nataša, i Boris Cota. 2007. „Modeling stock market volatility in Croatia“. *Ekonomska istraživanja* 20 (1): 1–7.

6. Friedman, Joseph, i Yochanan Shachmurove. 1997. „Co-movements of major European community stock markets: A vector autoregression analysis“. *Global Finance Journal* 8 (2): 257–277.

7. Gradojevic, Nikola, i Eldin Dobardzic. 2013. „Causality between Regional Stock Markets: A Frequency Domain Approach“. *Panoeconomicus* 60 (5): 633–47. doi:10.2298/PAN1305633G.

8. Granger, C. W. J. 1969. „Investigating Causal Relations by Econometric Models and Cross-spectral Methods“. *Econometrica* 37 (3): 424–38. doi:10.2307/1912791.

9. John Wei, K. C., Yu-Jane Liu, Chau-Chen Yang, i Guey-Shiang Chaung. 1995. „Volatility and price change spillover effects across the developed and emerging markets“. *Pacific-Basin Finance Journal* 3 (1): 113–36. doi:10.1016/0927-538X(94)00029-7.

10. Levine, Ross. 1997. „Financial Development and Economic Growth: Views and Agenda“. *Journal of Economic Literature* 35 (2): 688–726.

11. Levine, Ross, i others. 2000. „Bank-based or market-based financial systems: which is better?“ *University of Minnesota, mimeo*.

12. Morana, Claudio, i Andrea Beltratti. 2008. „Comovements in international stock markets“. *Journal of International Financial Markets, Institutions and Money* 18 (1): 31–45.

13. Olbrys, Joanna, i Elzbieta Majewska. 2014. „Direct Identification of Crisis Periods on the CEE Stock Markets: The Influence of the 2007 U.S. Subprime Crisis“. *Procedia Economics and Finance*, International Conference on Applied Economics, ICOAE 2014, 14 (siječanj): 461–70. doi:10.1016/S2212-5671(14)00735-7.

14. Sajter, Domagoj, i Tomislav Ćorić. 2009. „(I) rationality of Investors on Croatian Stock Market: Explaining the Impact of American Indices on Croatian Stock Market“. *Zagreb International Review of Economics and Business* 12 (2): 57–72.

15. Sorić, Petar. 2008. „On the Impact of Kuna Exchange Rate on Croatian Foreign Trade Results: Elasticity Approach“. U *Young Economist Seminar to 14th Dubrovnik Economic Conference 25. lipnja 2008*, 1–21.
16. Škrinjarić, Tihana. 2014. „Testing for regime-switching CAPM on Zagreb Stock Exchange“. *Croatian Operational Research Review* 5 (2): 119–133.
17. Škrinjarić, Tihana, i Vedran Kojić. 2014. „MODELIRANJE PRINOSA DIONICA NA ZAGREBAČKOJ BURZI POMOĆU MARKOVLJEVIH LANACA“. *Ekonomski pregled* 65 (3): 207–221.
18. Tomić, Bojan, i Andrijana Sesar. 2015. „Interdependence of Industrial Production Index and capital market in Croatia: VAR model“.
19. Tomić, Bojan, Andrijana Sesar, i Tomislav Džaja. 2014. „Komparativna analiza europskog tržišta kapitala i Dow Jones Industrial Average indeksa“.
20. Vizek, Maruška, i Tajana Dadić. 2006. „Integration of Croatian, CEE and EU equity markets: cointegration approach“. *Ekonomski pregled* 57 (9–10): 631–646.

Pravilnici i zakoni:

1. Zagrebačka burza d.d., (2008): Odluka o indeksu Zagrebačke burze: CROBEX http://zse.hr/userdocsimages/legal/Indeks2008.pdf (04.05.2017.)

Internet izvori:

1. https://www.google.com/finance(25.7.2017.)
2. https://finance.yahoo.com/(25.7.2017.)
3. http://zse.hr/default.aspx?id=44101&index=CROBEX (27.5.2017.)
4. http://www.ljse.si/(27.5.2017.)
5. http://www.belex.rs/(27.5.2017.)

6. http://www.investopedia.com/ (25.07.2017.)
7. http://zse.hr/default.aspx?id=77901 (07.08.2017.)

8. POPIS GRAFIČKIH PRIKAZA

1. Grafički prikaz 1 Sastav CROBEX indeksa 24
2. Grafički prikaz 2 Prikaz podataka i nepodudaranja radnih dana u različitim zemljama . 27
3. Grafički prikaz 3 Prikaz uređenih podataka 28
4. Grafički prikaz 4 Kretanje zaključne cijene CROBEX indeksa na dan trgovanja u razdoblju od 2012-2016 30
5. Grafički prikaz 5 Kretanje zaključne cijene S&P500 indeksa na dan trgovanja u razdoblju od 2012-2016 31
6. Grafički prikaz 6 Kretanje zaključne cijene DJI indeksa na dan trgovanja u razdoblju od 2012-2016 31
7. Grafički prikaz 7 Kretanje zaključne cijene FTSE100 indeksa na dan trgovanja u razdoblju od 2012-2016 32
8. Grafički prikaz 8 Kretanje zaključne cijene DAX indeksa na dan trgovanja u razdoblju od 2012-2016 32
9. Grafički prikaz 9 Diferencirane i logaritmirane vrijednosti dnevnih prinosa CROBEX indeksa 36
10. Grafički prikaz 10 Diferencirane i logaritmirane vrijednosti dnevnih prinosa S&P500 indeksa 37
11. Grafički prikaz 11 Diferencirane i logaritmirane vrijednosti dnevnih prinosa DJI indeksa 37
12. Grafički prikaz 12 Diferencirane i logaritmirane vrijednosti dnevnih prinosa FTSE100 indeksa 38
13. Grafički prikaz 13 Diferencirane i logaritmirane vrijednosti dnevnih prinosa DAX indeksa 38

14. Grafički prikaz 14 Korelacija između indeksa CROBEX, S&P500, DJI, FTSE100 i DAX 40

15. Grafički prikaz 15 Rezultati stabilnosti modela 48

16. Grafički prikaz 16 Rezultati impulsnog odziva Modela A 51

17. Grafički prikaz 17 Rezultati impulsnog odziva Modela B 57

9. SAŽETAK

U ovome radu prezentirani su radovi na temu financijskog prelijevanja između velikih razvijenih svjetskih kapitalnih tržišta te isto tako i radovi u kojima se ispituje utjecaj spomenutoga prelijevanja na tržišta u razvoju kao što je i hrvatsko. Predmet ovoga istraživanja predstavlja utvrđivanje kratkoročnih utjecaja američkih S&P500 i DJI tržišnih indeksa i europskih DAX i FTSE100 indeksa na hrvatski indeks tržišta kapitala, CROBEX.

Empirijski dio rada prikazuje rezultate vektorskih autoregresijskih modela (VAR modela) koji temeljeni na dnevnim podacima ocjenjuju međuodnose i utjecaj američkih indeksa S&P500 i DJI te europskih indeksa DAX i FTSE100 na hrvatski CROBEX indeks. Istraživanje obuhvaća dnevne podatke o zaključnim vrijednostima indeksa u poslijekriznom razdoblju od 1.1.2012. do 31.12.2016., kako bi se utvrdilo jesu li obrasci međuovisnosti kretanja indeksa zabilježeni u znanstvenim radovima prije krize (Vizek i Dadić 2006; Erjavec i Cota 2007; Sajter i Ćorić 2009) zadržali svoje karakteristike.

Rezultati su pokazali postojanje značajnog utjecaj kretanja američkih S&P500 i DJI indeksa na kretanje CROBEX indeksa. Utjecaji europskih kapitalnih tržišta nisu pokazali dovoljno značajne utjecaje na hrvatsko kapitalno tržište. Ako usporedimo rezultate ovoga istraživanja i zaključke ranijih istraživanja možemo zaključiti da se ponašanje investitora na hrvatskom tržištu kapitala nije značajno promijenilo u odnosu na razdoblje prije krize te da je utjecaj informacija s američkog tržišta još uvijek vrlo snažan.

Ključne riječi: financijsko prelijevanje, financijska kriza, VAR model, CROBEX

JEL klasifikacija: F37, G15

10. SAŽETAK NA ENGLESKOM JEZIKU

This study presents papers on financial spillover between major developed world capital markets and papers in which is presented the impact of the above mentioned spillover on the emerging markets, such as the Croatian one. The subject of this study is to determine the short-term effects of the US S&P500 and DJI market indices and the European DAX and FTSE100 indices on the Croatian capital market index, CROBEX.

The empirical part of the paper shows the results of vector autoregression models (VAR models) based on daily data estimating the interrelationships and effects of US indices S&P500 and DJI, and the European indices DAX and FTSE100 on the Croatian CROBEX index. The study includes daily data on closing values of the index in the post-crisis period from 1.1.2012. to 31.12.2016, in order to determine if the patterns of interdependence of index movement were recorded in scientific papers prior to the crisis (Vizek and Dadić 2006, Erjavec and Cota 2007, Sajter and Ćorić 2009) retained their characteristics.

The results showed that there was a significant impact of the S&P500 index on the movement of the CROBEX index, and that the influence of the DJI index on the movement of the CROBEX index was also significant. The effects of the European capital markets have not shown significant impact on the Croatian capital market. Comparing the results of this study and the conclusions of earlier research we can conclude that the behavior of investors on the Croatian capital market has not changed significantly in comparison to the pre-crisis period and that the impact of information from the US market is still very strong.

Key words: financial spillover, financial crisis, VAR model, CROBEX

JEL Classification: F37, G15