CIJENE NAFTE I FINANCIJSKA TRŽIŠTA

Klepo, Marko

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:124:604232

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

zir.nsk.hr

UNIVERSITY OF SPLIT

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U SPLITU

EKONOMSKI FAKULTET

DIPLOMSKI RAD

CIJENE NAFTE I FINANCIJSKA TRŽIŠTA

Mentor:

izv. prof. dr. sc. Ana Rimac Smiljanić

Student:

Marko Klepo

2150573

Split, lipanj, 2018.

SADRŽAJ:

1. UVOD 1

1.1. Problem istraživanja 1

1.2. Predmet istraživanja 3

1.3. Ciljevi istraživanja 4

1.4. Istraživačke hipoteze 4

1.5. Metode istraživanja 5

1.6. Struktura diplomskog rada 6

1.7. Doprinos istraživanja 7

2. TEORIJSKI ASPEKTI POVEZANOSTI TRŽIŠTA NAFTE I FINANCIJSKIH TRŽIŠTA 8

2.1. Volatilnost tržišta nafte 8

2.2. Promjene cijene nafte i posljedice na gospodarstvo 11

2.3. Veza cijene nafte i tržišta kapitala 13

2.4. Tržište dionica i značaj nafte za izabrane zemlje 23

3. REZULTATI EMPIRIJSKOG ISTRAŽIVANJA 36

3.1. Opis podataka 36

3.2. Metodologija istraživanja 37

3.3. Rezultati istraživanja 38

3.3.1. Njemačka 38

3.3.2. Francuska 42

3.3.3. Austrija 46

3.3.4. Slovenija 50

3.3.5. Hrvatska 54

3.3.6. Italija 58

3.3.7. Norveška 62

3.3.8. Rusija 66

3.4. Rasprava istraživanja 70

4. ZAKLJUČAK 73

LITERATURA 74

POPIS GRAFIKONA 79

POPIS SLIKA 80

POPIS TABLICA 81

PRILOZI: 83

SAŽETAK 90

SUMMARY 91

1. UVOD

1.1. PROBLEM ISTRAŽIVANJA

Razina razvoja pojedine ekonomije ovisi o mnogim faktorima koji mogu biti uvjetovani različitim obilježjima i odrednicama. Ti faktori mogu biti determinirani geografskim položajem i prirodnim resursima ili drugim varijablama koje su čiste ekonomske prirode. Među jedne od glavnih ekonomskih faktora koji doprinosi razvoju možemo navesti su nivo štednje, odnosno investiranja. Investiranje je ključ razvoja mnogih država i pametna politika poticanja investiranja, bilo da je ona planski određena ili podrazumjeva neplanske akcije, je nužna i potrebna. U modernim društvima za mobiliziranje štednje mogu se koristiti bankovno zaduživanje kao i različiti pojavni oblici tržišta, primjerice tržišta dionica ili obveznica. Tržišta dionica predstavljaju glavni izvor financiranja vlastitih sredstava poduzeća, te je kretanje njihove vrijednosti jedan od bitnih čimbenika koji određuje ulagačku politiku ulagača. Na cijene dionica utječu mnoge odrednice poduzeća, ali i okruženja, poput cijena nafte.

Sidiqqi (2014.) navodi kako postoje različiti interni i eksterni (makroekonomski) faktori koji određuju cijene dionica na burzovnim tržištima. On navodi kako su interni faktori najčešće profitna marža, dinamika zarada, novi izumi, udio na tržištu, reputacija managementa i rasprostranjenost kompanije s obzirom na geografski položaj i proizvodni portfolio. Degiannakis et al.(2011.) navode da su još 30-ih godina Fisher i Williams tvrdili kako bi cijena bilo koje imovine trebala biti određena očekivanim diskontiranim gotovinskim tijekovima od te imovine. Sidiqqui (2014.) kao glavne makroekonomske varijable navodi bruto društveni proizvod, inflaciju, novčanu masu, visinu kamatnih stopa i njihove promjene, realni devizni tečaj, kamatne stope na globalnom tržištu, cijene zlata i nafte, liberalizaciju trgovine itd. Gay (2016.) u svom radu navodi kako je utjecaj različitih makroekonomskih varijabli na dionička tržišta dokazan za razvijene ekonomije, no također postavlja isto pitanje i za zemlje u razvoju. Mnogi drugi autori koji se bave ovim područjem istraživanja dobivaju različite rezultate u ovisnosti o specifikacijama same ekonomije. Od ostalih nemikroekonomskih varijabli čiji je utjecaj značajan na burzovna tržišta zasigurno se može izdvojiti i cijene nafte, te njihovo kretanje na svjetskom

tržištu. Canedo Donoso (2009.) u svom radu tvrdi kako su ekonomija i sama burzovna tržišta osjetljivija, na primjeru SAD-a i Ujedinjenog Kraljevstva u odnosu na Japan, na promjene cijena nafte. Park i Ratti (2007.) na temelju istraživanja koje obuhvaća SAD i 13 europskih država zaključuju kako na primjeru Norveške postoji pozitivna veza između kretanja burzi dionica i cijena nafte dok je u mnogim drugim europskim zemljama trend obratan. U istom radu autori navode kako je u mnogim zemljama, uključujući i SAD utjecaj kretanja cijena nafte na burze veći nego primjerice utjecaj kamatnih stopa. Kroz navedeni primjer vidi se sama razlika između utjecaja promjena cijena nafte na zemlje neto uvoznice (npr. zemlje EU-a) i neto izvoznice nafte (npr. Norveška). Prema Brose Olsen i Heinriz (2014.) fluktuacije cijena nafte utječu na financijska tržišta na mnoge načine, kroz razne kanale. Tako navode da ukoliko dođe do rasta cijena nafte tada će i porasti cijene inputa mnogih dobara što će utjecati na troškove poduzeća koja ih proizvode i na cijenu njihovih proizvoda. Također, ako je poduzeće proizvođač nafte i derivata, tada će to utjecati na njihove prihode, a sve posljedično i na vrijednost same kompanije. Dugi kanal na koji utječu je kanal utjecaja na pojedinu zemlju. Prema tom kanalu ovisi je li je zemlja uvoznik ili izvoznik nafte, te će primjerice pad/porast cijene nafte utjecati na njen saldo vanjsko-trgovinske bilance. Primjerice ukoliko je zemlja uvoznik nafte, tada će negativan saldo vanjsko-trgovinske bilance stvoriti deflacijske pritiske na tečaj što će rezultirati većom očekivanom inflacijom. Veća inflacija je povezana sa većom stopom diskontiranja vrijednosti poduzeća, što ima utjecaj na primjerice pad vrijednosti poduzeća, dionica. Također realne kamatne stope ovisiti će o cijeni nafte.

Glavno istraživačko pitanje u ovom radu je kako cijene nafte na svjetskom tržištu utječu na tržišta kapitala. Kroz sam razvoj ekonomske misli veliki broj ekonomista se bavio ovim pitanjem, te su došli do različitih rezultata, ali se većina slaže da utjecaji postoje, dok se o intenzitetu samih i dalje „lome koplja“. Pojedini istraživači same šokove cijena nafte, odnosno nagle promjene, dijele u tri različite vrste: šokove ponude, globane agregatne šokove potražnje i specifične šokove potražnje za naftom (Apergis i Miller, 2009.). Autori poput Mohanty et al. (2013.) ne dijele same šokove po različitim uzrocima jer tvrde kako je teško razlučiti uzrok pojedinog šoka cijene te se sami uzroci krivo promatraju.

O samom smjeru i intenzitetu utjecaja kretanja cijena nafte na povrate na tržištu kapitala već je napisano dosta znanstvene literature. Bams et al. (2017.) tvrde kako šokovi cijena nafte, odnosno

sama nesigurnost koja iz njih proizlazi, imaju samo značajan utjecaj samo u sektorima gospodarstva koji su vezani uz naftu kao svoj input. Ahmadi et al. (2016.) dobivaju različite rezultate za različite uzroke šokova, te se iz njihovih rezultata isčitava kako su šokovi potražnje značajniji po intenzitetu od drugih šokova. Bastiani et al. (2016.) prikazuju kako šokovi ponude nafte koji utječu na samu cijenu nemaju utjecaja na volatilnost povrata na tržištu kapitala na uzorku G7 zemalja. Također, tvrde kako na samu volatilnost imaju značajnog utjecaja šokovi potražnje. Na primjeru Kine, Wei i Guo (2017.) pokazuju kako su efekti šokova cijena nafte na povrate na tržištu kapitala dosta nestabilni, te tvrde kako sami šokovi imaju više utjecaja na povrat na tržištu kapitala, nego na samu volatilnost dionca. Istraživanje Pinho i Madaleno (2016.) pronalazi rezultat kako šok cijena nafte ima drukčije transmisijske mehanizme u različitim sektorima, te navode primjer industrija nafte i plina kao jedan od sektora gdje su utjecaji izraženiji. Antonakakis et al. (2017.) također provode istraživanje na zemljama uvoznicama i izvoznicama nafte te dolaze do sličnih rezultata kao i Wang et al. (2013.). Tvrde kako efekt šokova cijena nafte uvelike ovisi o samoj prirodi zemlje, ovisno o tome uvozi li ili izvozi naftu i o samoj bitnosti nafte kao sirovine u ekonomiji. Također, tvrde da su nestabilni šokovi agregatne potražnje puno očitiji u zemljama izvoznicama nego uvoznicama.

1.2. PREDMET ISTRAŽIVANJA

Uočeni opisani problem o poveznici između financijskih tržišta i cijena nafte nameće i predmet ovoga rada. U radu istražen je utjecaj cijena nafte na tržište kapitala s posebnim naglaskom na razliku među zemljama, tj. jesu li zemlje uvoznice i/ili izvoznice nafte. Istraživanje je fokusirano na promatranje utjecaja promjena cijena nafte na burzovne indekse. Salisu i Isah (2017.) u svom radu navode kako postoji veza između promatranih varijabli kako za zemlje uvoznice, tako i za zemlje izvoznice nafte. Aydogan et al.. (2017.) pronalaze kako je povezanost veća u zemljama uvoznicama nego zemljama izvoznicama. Također kao jedna od zemalja uvoznica analizirana je i Republika Hrvatska za koju ne postoji veliki broj sličnih istraživanja koja se bave bliskom tematikom. Od zemalja uvoznica nafte analizirane su Slovenija, Austrija, Njemačka, Francuska i Italija. Navedene zemlje su izabrane prema tome što su sve članice Europske unije, ali i zato što ih možemo podijeliti u dvije skupine, jedne koje su svoja tržišta razvila tek nedavno u

posljednjih 25 godina od pada komunizma i prelaska u tržišno gospodarstvo, dok za ostale možemo reći kako su „starije“ demokracije sa razvijenijim financijskim tržištima i samim ekonomijama. Od zemalja izvoznica analizirane su Norveška i Rusija koje također imaju slične karakteristike u povijesti razvoja svog tržišta. Obje zemlje se nalaze na teritoriju Euro-Azije, te nisu članice Europske unije. Norveška, iako nije članica Unije, sama je jako integrirana u europska kretanja te je po razini razvijenosti ne samo gospodarstva i tržišta, već i instucija i demokracije općenito možemo svrstati uz bok najrazvijenijih zemalja. Rusija u bitnome predstavlja suprotnost Norveškoj, institucionalan i demokratski razvoj kao i razvijenost samog gospodarstva možda se ne mogu usporediti sa najrazvijenijim državama, ali ova zemlja predstavlja izrazito zanimljiv predmet istraživanja zbog svoje zavisnosti o nafti kao i svoje povezanosti sa razvijenijim ekonomijama zapada što se možda najbolje vidi kroz sama ulaganja u proizvodnji na teritoriju Ruske Federacije.

1.3. CILJEVI ISTRAŽIVANJA

Glavni cilj ovog istraživnja je objasniti utjecaj promjena cijena nafte na financijska tržišta, odnosno kretanje burzovnih indeksa. U radu će naglasak je stavljen na analizu i objašnjenje navedenog problema, utjecaja promjene cijene nafte na svjetskom tržištu, na burzovna tržišta razlikujući zemlje neto uvoznice i neto izvoznice nafte. Dodatno, cilj ovoga rada je utvrditi postoji li različit utjecaj promjene cijene nafte na tržišta u zemljama koje su neto uvoznik ili neto izvoznik nafte.

1.4. ISTRAŽIVAČKE HIPOTEZE

S obzirom na temu rada, problem, predmet i ciljeve istraživanja zadane su sljedeće hipoteze:

H1: Promjena cijena nafte utječe na na tržišta kapitala.

U industijaliziranim zemljama i zemljama koje imaju veliku potrošnju nafte veliki dio kompanija je koje su izlistane na burzama ovise o cijenama nafte, zbog toga što je nafta u većoj ili manjoj mjeri jedan od primarnih inputa u procesima proizvodnje kako dobara tako i usluga. Kroz

problem istraživanja već je prikazano kako cijena nafte može utjecati kroz razne kanale na vrijednost samog poduzeća, primjerice na povećanje troškova ili uzrokovati stvaranje deflacijskih pritisaka koji mogu rezutirati većom očekivanom inflacijom i većom stopom diskontiranja (Broose Olsen i Henriz, 2014.). Canedo Donoso (2009.) u svom radu iznosi hipotezu kako promjena cijene nafte utječe na indekse na tržištu dionica. Rezultati njegovog istraživanja potvrđuju kako su ekonomije SAD-a i Ujedinjenog Kraljevstva osjetljivije na negativne šokove, dok je u slučaju Japana situacija drukčija. Dhaoui i Khraief (2014.) pronalaze negativne utjecaj promjene cijena nafte na burze kroz utjecaj na povrate na tržištima kapitala kod 7 analiziranih zemalja dok kod Singapura ne nalaze značajniju vezu.

Druga postavljena hipoteza ovog rada glasi:

H2: Utjecaj promjena cijena nafte razlikuje se kod zemlja uvoznica od zemalja izvoznica.

Pri analizi utjecaja promjena cijena nafte na tržišta kapitala, u ekonomskoj literaturi veliki broj istraživanja ne razlučuje potencijalno različite utjecaje koji se mogu dogoditi radi toga što je pojedina zemlja neto uvoznik ili neto izvoznik nafte. Najveći broj istraživanja uzima za primjer SAD koji su kroz većinu moderne povijesti predstavljali najvećeg neto uvoznika nafte na svijetu. Kod zemalja uvoznica, u većini istraživanja postoji konsenzus, o negativnom utjecaju između porasta cijene i kretanja na tržištu kapitala. Neka od istraživanja koja to tvrde su Sadorsky (2001.), Bashar (2006.) i Jones i Kaul (1996.). U slučaju zemalja neto izvoznica Mueller (2009.) tvrdi kako zbog porasta cijene nafte te zemlje profitiraju radi većih cijena, no ipak postoje i negativni utjecaji i na njihovo gospodarstvo radi većih troškova.

Teorijskom i empirijskim istraživanjem prezentiranom u ovom radu daju se dokazi i analize kojima se potvrđuju odnosno odbacuju navedene hipoteze.

1.5. METODE ISTRAŽIVANJA

Kako bismo došli do konkretnih rezultata istraživanja, te kroz te rezltate prihvatili ili odbacili hipoteze u ovome radu korištene su različite metode istraživanja. U ovome radu korištene su metode istraživanja koje su prilagođene općenito društvenim znanostima, kao i specifične metode koje su primjerene ekonomskoj znanosti. Prikazana je logička veza između promatranih

varijabli i dano objašnjenje njihove veze pomoću metode analize. Također su objektivno i realno prikazani ekonomski fenomeni. Metoda klasifikacije korištena je kako bi se rezultate istraživanja klasificiralo ovisno o njihovom porijeklu u odnosu na različite zemlje, jednako kao i metoda komparacije kako bi se ti rezultati usporedili. Metoda analize i metoda kompilacije korištene su kako bi se dao pregled relevantne literature dosadašnjih ekonomskih istraživanja u ovom polju znanstvenog interesa. Pomoću metode apstrakcije odvojeni i naglašeni su bitni elementi predmeta istraživanja od manje bitnih vezano uz problem istraživanja. Metodom generalizacije od pojedinačnih rezultata, pojedinih zemalja, izvojeni su općeniti zaključci temeljeni na uporištu u stvarnosti. Kako bi se pokazao utjecaj pojedinih faktora, kvantifikacija i mjerljivost varijabli i njihova utjecaja je jedan od osnovnih ciljeva. Korištena je deduktivna metoda u pristupu istraživanju. Prvo je definirana generalna pretpostavka da cijene nafte utječu na financijska tržišta, te su u daljnjoj razradi na temelju uvjeta o tome dali je zemlja neto uvoznik ili neto izvoznik nafte definirani ciljevi i hipoteze. Na kraju su testirane hipoteze te izvedeni zaključci. Metodom dokazivanja i opovrgavanja utvrđena je točnost spoznaja kroz prihvaćanje i/ili opovrgavanje postavljenih hipoteza.

U empirijskoj analizi će se korištene su primjerene statističke i ekonometrijske metode. Burze vrijednosnica, točnije dionica i njihovi indeksi su jedan od primarnih objekata promatranja u ovom istraživanju te će biti određeni kao zavisna varijabla. Jedna od najčešćih mjera su tržišni, odnosno burzovni indeksi koji se koriste u ovome radu. Ti indeksi predstavljaju određen „pool“ dionica i putem njih je relativno lagano pratiti same promjene u stopi povrata.

Na temelju analize povezanosti promatranih varijabli izgrađen je ekonometrijski model koji je testiran pomoću analize vremenskih nizova, pomoću metode modeliranja.

1.6. STRUKTURA DIPLOMSKOG RADA

Rad se sastoji od četiri glavna dijela: uvoda, teorijskih aspekata povezanosti tržišta nafte i financijskih tržišta, rezultata empirijskog istraživanja i zaključka. Na samom kraju rada dan je popis korištene i relevantne literature, popis slika, tablica i grafikona, te sažetak.

U prvom poglavlju prikazan je uvod u rad. Kroz to poglavlje prikazani je predmet, cilj, metode i struktura rada naslova „Utjecaj cijena nafte na financijska tržišta“.

Kroz drugi dio rada naslova „Teorijski aspekti povezanosti tržišta nafte i financijskih tržišta“ izneseno je teorijsko uporište same problematike rada kao i pregled istraživanja koja su dosad proveli različiti autori. Također u ovom dijelu prikazana su obilježja samih tržišta dionica i nafte, te transmisijski kanali kojima se utjecaj promjene cijene prenosi na financijska tržišta.

U trećem dijelu rada naslova „Rezultati empirijskog istraživanja“ prikazan je opis podataka, metodologija i objašnjenje veza modela te rezultati empirijskog istraživanja. U ovom dijelu prikazani su rezultati i rasprava empirijskog istraživanja za sve zemlje.

U četvrtom dijelu iznesen je zaključak iza kojeg slijedi bibliografski popis, popis grafikona, slika i tabela, te sažetak.

1.7. DOPRINOS ISTRAŽIVANJA

Kroz ovo istraživanje analizirana je veza između cijena nafte na svjetskom tržištu i tržišta kapitala, odnosno burzi dionica. Rezultati istraživanja prikazuju utjecaj varijable cijena nafte na svjetskom tržištu na tržišta dionica. Rezultati i njihova rasprava se mogu shvatiti kao preporuke za ulaganje na financijskim tržištima izabranih zemalja. Doprinos je posebno značajan za Republiku Hrvatsku i Sloveniju za koje ne postoji značajan broj sličnih istraživanja. Također kroz ovaj rad prikazana je sinteza dosadašnjih relevantnih istraživanja o utjecaju cijene nafte na financijska tržišta čime su se bavili drugi autori.

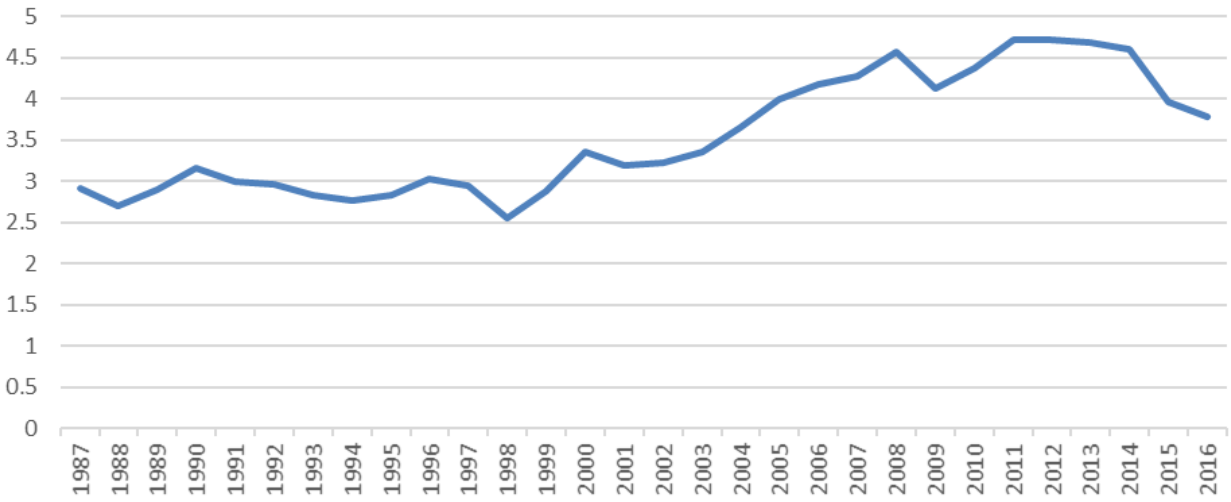
2. TEORIJSKI ASPEKTI POVEZANOSTI TRŽIŠTA NAFTE I FINANCIJSKIH TRŽIŠTA

2.1. VOLATILNOST TRŽIŠTA NAFTE

Nafta i naftni derivati predstavljaju jedan od najvažinijih resursa u današnjim gospodarstvima. Tržište nafte je kroz svoju povijest doživljavalo različita razdoblja stabilnosti cijena, kao i razdoblja većih oscilacija, odnosno volatilnosti, cijena. Nafta je jedan od glavnih resursa na kojima počiva današnja globalna ekonomija. U nekim zemljama je nafta izrazito značajna, npr. prema Alikhanov i Nguyen (2011.) 5% ukupne svjetske populacije živi u SAD-u, dok se istovremeno u SAD-u troši 25% svjetske potrošnje nafte.

Opće je poznato kako je nafta neobnovljiv izvor energije. Ovdje se najbolje vidi jedna od temeljnih premisa na kojima počiva ekonomska znanost: ograničenost resursa. Mnoge zemlje, koristeći se tom prednosti, posjedovanja nafte, omogućile su svojim građanima i/ili vlasnicima naftnih polja lagodniji život od ostatka svijeta. Tako je primjerice Norveška financirala mirovine svojih građana, ulagala u transfere i socijalna davanja itd.

Samo tržište nafte prije 1974. godine možemo promatrati kao veoma stabilno sa malim oscilacijama. Period od druge polovine 19. stoljeća pa do 1974. predstavlja relativno stabilno razdoblje sa kretanjem cijena između 10$ i 20$ po barelu. Organizacija zemalja izvoznika nafte je 1973. godine odlučila uvesti embargo na izvoz nafte u SAD zbog američke potpore Izraelu u ratnom sukobu sa Egiptom. Navedeni embargo, potaknut ratnim sukobom, doveo je do povećanja cijena nafte sa 13$ na 53$. Nakon navedenog sukoba cijena nafte je oscilirala u narednom razdoblju da bi početkom osamdesetih godina narasla na 95$ po barelu zbog iransko-iračkog ratnog sukoba. Krajem osamdesetih i u devedesetim godinama cijena pada na razinu između 20$ i 30$ da bi 2008. godine, u jednom trenutku, ponovno doživjela rast na vrtoglavih 145$. U narednom razdoblju cijena je ponovno oscilirala (Smith, 2009.). Na slici 1. može se vidjeti kretanje cijene nafte u razdoblju od 1987. godine do 2016. godine. U 2000. godini cijena nafte je porasla sa 17$ po barelu na 28$, dok je u razdoblju između 2004. godine i 2008. godine cijena porasla sa 38$ po barelu na 97$. Na slici 1. prikazane su oscilacije tako da su cijene na BRENT tržištu stavljene pod prirodni logaritam.



Grafikon 1: Oscilacije cijene nafte 1987.-2016. (godišnje)

Izvor: Izrada autora, prema podacima preuzetim sa: https://www.eia.gov/dnav/pet/pet_pri_spt_s1 _a.htm., pristupljeno na datum 20.03.2018.

Napomena: „Na osi Y su prikazane su cijene nafte na BRENT tržištu, stavljene pod prirodni logaritam."

Kroz ekonomsku literaturu navodi se kako potražnja za naftom ovisi uvelike o različitim varijablama. Primjerice u slučaju slabijeg rasta ili pada stope rasta BDP-a, potražnja za naftom će slabije rasti, odnosno padati što će uvelike imati utjecaj na cijenu. U slučaju rasta cijena nafte, kod zemalja izvoznica rast BDP-a će biti posljedica rasta potražnje, a time i cijene. Kada se u odnos stave veličina populacije, odnosno kretanje rasta populacije, tada se može primjetiti kako sa rastom populacije raste i potražnja za naftom. Utjecaj na potražnju u pojedinim zemljama, a samim time i na cijenu mogu imati i velika postrojenja poput primjerice rafinerija i industrija u kojima se nafta i proizvodi iz nafte proizvode u velikom udjelu.

Nafta kao i svako dobro kojim se bavimo kroz ekonomiju ima jedno bitno obilježje, a to je ograničenost. Zbog ograničenosti samog dobra bitno je spomenuti i ponudu nafte. Prema javno dostupnim podatcima unatrag nekoliko godina zemlje OPEC-a su proizvodile oko 40% svjetske nafte te se njihov utjecaj na cijenu kroz manipulacije količinama i dostupnošću samog resursa može primjetiti, samo spomenimo već prije navedene sukobe u 70-im i 80-im godinama na Bliskom istoku. Jednako bitan proizvođač je i Rusija koja je u 2016. godini zadržala prvo mjesto na kojem stoji već više od 10 godina, naravno ako zemlje OPEC-a gledamo pojedinačno. Proizvodnja i ponuda u SAD-u je počela također rasti krajem prvog desetljeća 21. stoljeća na što

je imao veliki utjecaj imala i popularizacija proizvodnje nafte iz nekonvencionalnog izvora naftnog škriljevca. Naftni škriljevac je vrsta stijene iz koje se preradom može pomoću kemijskog procesa dobiti nafta. Jedna od bitnih odrednica kod formiranja ponude, a i cijene nafte su i dokazane reserve samog resursa. Kod ponude nafte također bito je spomenuti i strukturu kompanija koje se bave proizvodnjom. U zemljama OPEC-a većina kompanija je u vlasništvu države. Kod Rusije i Norveške znatan utjecaj na proizvodnju ima također država, bilo kroz vlasništvo ili sami utjecaj političkih elita. Zemlje zapada karakterizira u velikoj većini privatno vlasništvo kompanija. U tablici 1. prikazano je 20 najvećih svjetskih kompanija, te njihovo vlasništvo, prozvodnja i rezerve.

Tablica 1: 20 najvećih svjetskih naftnih kompanija u 2007. godini

Rank	Tvrtka	Država	Državnio vlasništvo u %	Proizvodnja u tisućama barela	Rezerve u milijunima barela
1.	**Saudi Aaramco**	**Saudijska Arabija**	100	10,413	264,200
2.	**NIOC**	**Iran**	100	4,401	138,400
3.	**Pemex**	**Meksiko**	100	3,474	12,187
4.	**CNPC**	**Kina**	100	2,764	22,447
5.	Exxon Mobil	SAD		2,616	11,074
6.	**KPC**	**Kuvajt**	100	2,600	101,500
7.	**PDV**	**Venezuela**	100	2,570	99,377
8.	BP	UK		2,414	10,073
9.	**INOC**	**Irak**	100	2,145	115,000
10.	Rosneft	Rusija	75.16	2,027	17,513
11.	Petrobas	Brazil	32.2	1,918	9,581
12.	Shell	UK/Nizozemska		1,899	4,887
13.	**Sonatrach**	**Alžir**	100	1,860	11,400
14.	Chevron	SAD		1,783	7,523
15.	ConocoPhillips	SAD		1,644	6,541
16.	**Adnoc**	**UAE**	100	1,574	52,800
17.	Lukoil	Rusija		1,552	12,572
18.	Total	Francuska		1,509	5,778
19.	**NNPC**	**Nigerija**	100	1,414	21,700
20.	**Lybya NOC**	**Libija**	100	1,368	30,700

Izvor: Smith (2009.)

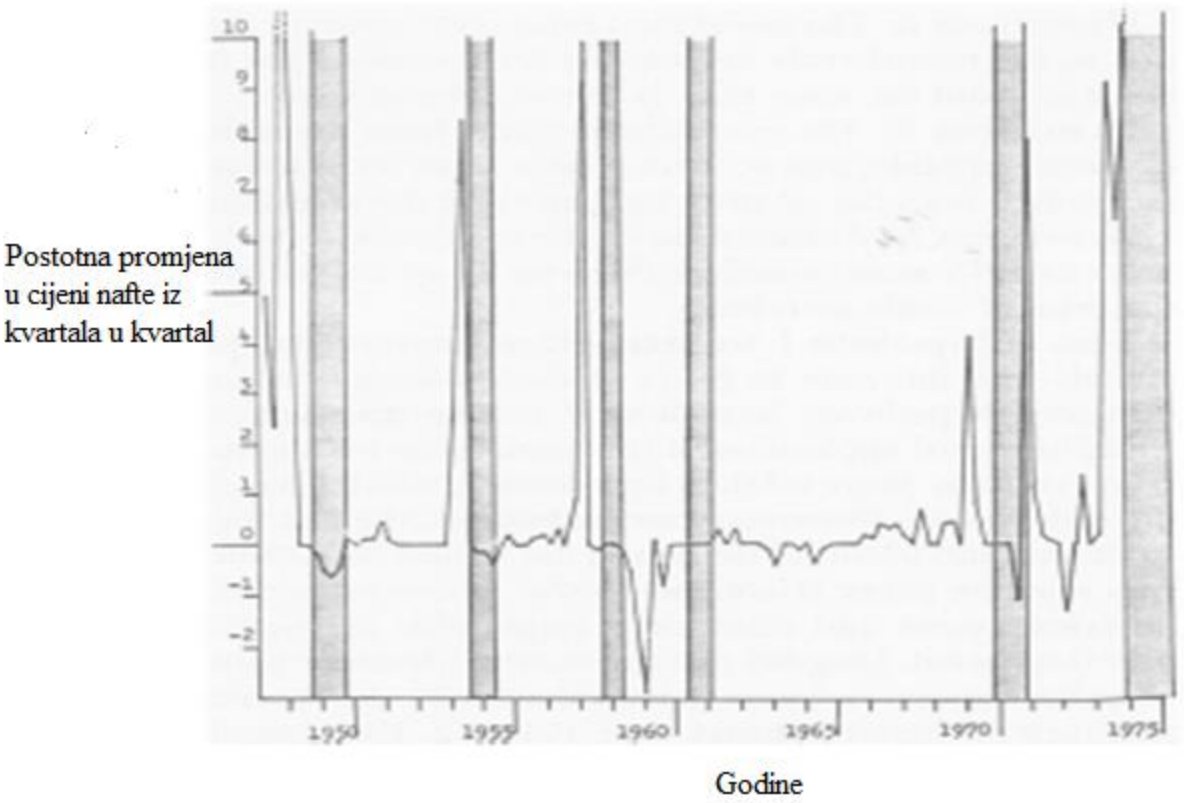
Nafta i naftne prerađevine su kroz prošlosti imale veliki udio u svjetskoj trgovini. Smith (2009.) navodi kako je 13% svjetske trgovine u 2006. godini pripadalo ovoj skupini dobara, odnosno oko 4 milijarde dolara dnevno. U istom radu uspoređuje automobilsku industriju i industriju željeza i čelika koje imaju udio od 1.5, odnosno 1 milijardu dolara dnevno. Prema njegovim podatcima

oko 50 zemlja na svijtu proizvodi dovoljnu količinu nafte za vlastite potrebe, dok su sve ostale neto uvoznici, ali navodi kako su sve zemlje u većoj ili manjoj mjeri pogođene kretanjima cijena nafte.

2.2. PROMJENE CIJENE NAFTE I POSLJEDICE NA GOSPODARSTVO

Promjene cijena nafte osim posljedica na tržišta imaju i posljedice na realnu ekonomiju. Porast cijena nafte utječe na smanjivanje profitabilnosti poduzeća kroz širok spektar različitih industrija u kojima je nafta bitan resurs. Veće volatilnosti, i porast cijene nafte imaju utjecaj na krajnjeg potrošača i njegov raspoloživi dohodak. Kako bi prikazali prethodno, možemo naftu usporediti s porezom na dodanu vrijednost (PDV). Znamo kako se PDV prelijeva kroz proizvodni lanac sa proizvođača na krajnjeg potrošača, kako bi se izbjeglo višestruko oporezivanje. U slučaju rasta navedenog poreza, iznos rasta poreza će se prenijeti na krajnjeg potrošača, isto tako u slučaju porasta cijene nafte, proizvođači i svi u lancu proizvodnje, prerade i distribucije proizvoda i usluga u kojima nafta čini bitan input nastojati će to povećanje cijena prenijeti na krajnjeg potrošača (konzumenta) čiji će raspoloživi dohodak biti stoga manji. Manji raspoloživi dohodak može imati za posljedicu smanjivanje opće potrošnje i/ili agregatne ekonomske aktivnosti zbog smanjene agregatne potražnje. Također u drugom slučaju poduzeća mogu u slučaju rasta cijene inputa smanjiti količinu proizvoda na tržištu i time dignuti cijene proizvoda, te smanjiti rasploživi dohodak.

Jedan od prvih istraživača koji se počeo baviti utjecajem nafte na ekonomiju bio je James D. Hamilton koji je u svom radu iz 1983. godine utjecaj nafte na ekonomiju poslije 2. Svjeskog rata. On u svome radu naziva „Oil and the Macroeconomy since World War II“ tvrdi kako su sve poslijeratne recesije u SAD-u bile predviđene ¾ godine prije nego su se dogodile. Prema njegovim podatcima za razdoblje od 1948.-1972. naftni šokovi su bili uzrok najmanje jedne recesije (1972.).



Slika 1: Cijena nafte i recesije u SAD-u

Izvor: Hamilton (1983.)

Prema Hamiltonu (1983.) na slici 1. se vidi da se cijena nafte u predviđanju recesija u navedenom razdoblju ponašala kao vodeća varijabla. Hamilton u svom radu zaključije kako je 7 od 8 poslijeratnih recesija u SAD-u bilo predviđeno povećanjem cijena nafte. Prema njemu postoji značajna veza između kretanja cijena nafte i agregatnog ouputa.

Anand et al.(2014.) tvrde kako je val inflacija koji je zadesio mnoge zemlje u svijetu tokom 70.-ih godina prošlog stoljeća bio posljedica porasta cijena nafte na svjetskom tržištu. Ograničavanje ponude nafte na tržištu prema Hamilton (2003., u Anand et al., 2009.) će za posljedicu imati smanjivanje inputa u proizvodnji što u konačnici može rezultirati sporijim rastom gospodarstva. Šokovi naftnih cijena također mogu imati i utjecaja na smanjenje produktivnosti proizvodnje, te uzrokovati veće fluktuacije u poslovnim ciklusima, Olson (1998., u Anand et al., 2009.). Basher i Sadorsky (2006.) tvrde da su ekonomije u razvoju su osjetljivije na šokove promjena cijena nafte od razvijenih ekonomija, zbog toga što su njihova gospodarstva više ovisna o nafti u samom proizvodnom procesu. Arouri et al. (2011.) tvrdi kako je kroz dosadašnju literaturu utvrđeno

kako veza između fluktuacija cijena nafte i kretanja ekonomske aktivnosti nije linearna, te da je općenito gospodarska aktivnost osjetljivija na negativne naftne šokove. Navedeni autori tvrde kako je u prošlosti većina istraživanja pokazivala na prethodnu premisu za zemlje u razvoju kao i razvijene, no ipak u današnjem svijetu očigledna je i pozitivana veza između ekonomskog rasta i rasta potražnje za naftom.

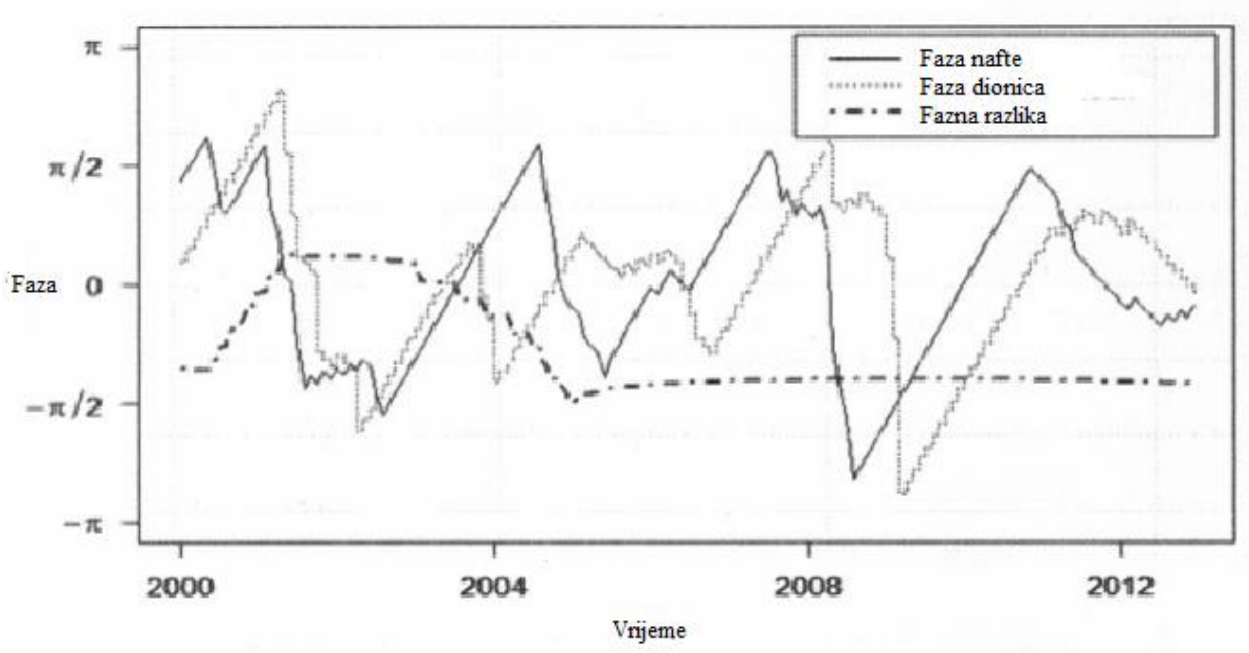
2.3. VEZA CIJENE NAFTE I TRŽIŠTA KAPITALA

O vezi cijene nafte i tržišta kapitala u proteklih tridesetak godina objavljen je čitav niz znanstvenih članaka koji se bave tom tematikom, kao i detektiranjem utjecaja na ukupnost svjetskog gospodarstva kao i pojedinih zemalja. Ovisno o istraživanju, najčešće se koriste cijene po barelu sa BRENT tržišta sirove nafte ili „Western Texas Intermediate“ tržišta (WTI), ovisno o tome koje zemlje se analiziraju. Za europske zemlje u pravilu se koriste BRENT cijene, dok primjerice za SAD, WTI cijene. Istraživanja najčešće koriste mješovite indekse burzi vrijednosnica, no ima i slučajeva u kojima se koriste i industrijski i slični indeksi ovisno o cilju istraživanja autora. Zbog kompleksnosti gospodarskog sustava, veliki dio autora (primjerice Jones i Kaul, 1996.; Rashid, 2008.; Ogiri et al., 2013.; Zhou i Wang, 2013.), koristi i pomoćne varijable u objašnjavanju kretanja burzovnih indeksa. Te varijable su najčešće inflacija, varijable koje pokazuju realnu ekonomsku aktivnost (BDP ili indeks industrijske proizvodnje), nominalne ili realne tečajeve i kamatne stope.

Alikhanov i Nguyen (2011.) u svom radu istražuju vezu između nafte i dioničkih indeksa (mješoviti i industrijski) za Norvešku i Rusiju, u razdoblju od siječnja 1998. do ožujka 2011. Kao dodatne varijable uzimaju, osim cijene nafte na BRENT tržištu, kamatne stope, realni devizni tečaj svake valute prema dolaru, indeks industrijske proizvodnje. Kroz VAR model može se vidjeti kako cijena nafte utječe na indekse obiju ekonomija, te da je veći utjecaj kod industrijskih nego li mješovitih indeksa. Prema njihovom istraživanju devizni tečaj i međubankovne kamatne stope imaju negativan utjecaj, dok indeks industrijske proizvodnje nema značajnog utjecaja na promatrane indexe.

Jones i Kaul (1996.) istražuju utjecaj naftnih šokova na tržišta SAD-a, Ujedinjenog kraljevstva, Kanade i Japana. Kao varijable koriste realnu stopu povrata na obične dionice i indeks industrijske proizvodnje. Dobiveni rezultati, pomoću Grangerova modela, ukazuju na to da su tržišta dionica u SAD-u i Kanadi racionalna, odnosno da se reakcija cijena dionica na naftne šokove u potpunosti može pripisati utjecaju šokova na tekuće i očekivane buduće realne novčane tijekove, koji su predstavljeni varijablom indeks industrijske proizvodnje.

Anand et al. (2014.) u svojoj empiriskoj analizi koriste parametrizaciju BEKK bivarirajućeg GARCH modela i alate kontinuiranih „wavelet" transformacija kako bi dobili podatke o efektima prelijevanja sa jednog tržišta na drugo. Analiza je podijeljena na dva dijela, sa listopadom 2008. Prvo razdoblje je od početka 2000. do listopada 2008., dok drugo nastavlja do 2012. godine. „Empirijski rezultati sugeriraju da je nakon izbijanja financijske krize došlo do eskalacije u magnitudi volatilnosti efekata prelijevanja između povrata na tržištu nafte i povrata na tržištu kapitala", tvrde Anand et al. (2014., str. 53.). Prema rezultatima wavelet analize u post i pred kriznom periodu koherentna veza između dviju varijabli je postala jača u pojasevima viših frekvencija (Slika 2.).



Slika 2: Faze i fazna razlika naftnih povrata i povrata na tržištu kapitala

Izvor: Anand i Ramachandran (2014.)

Killan i Park (2009.) u svom radu razvijaju drukčiji pristup od prethodnih istraživanja, te promatraju naftne šokove prema različitim uzrocima. Istraživanje pokazuje kako šokovi ponude i potražnje za sirovom naftom zajedno čine oko 22% uzroka u volatilnosti povrata na tržištu kapitala u SAD-u.

Arouri et al. (2011.) ispituju vezu između nafte i tržišta kapitala na primjeru europskih zemalja u razdoblju od siječnja 1997. (poslije Azijske krize) do studenog 2008. U svojoj analizi zaključuju kako su vremenske serije nestacionarne, te pomoću kointegracijskog testa ne nalaze kointegracijsku vezu među varijablama. Autori pronalaze jaku vezu između cijena nafte i industrija poput Automobili i automobilski dijelovi i Nafta i plin. Također pronađena je veza i između sektora Financija i Tehnologije sa cijenama nafte. Istraživači zaključuju kako ova studija pokazuje da povećanje cijena nafte nema samo utjecaja na potencijalno povećanje marginalnih troškova u kompanijama, već i na veći ekonomski rast, povjerenje potrošača i potražnju za prozvodima.

Guesmi et al. (2016.) istražuju utjecaj promjene cijene nafte na američki Dow Jones Industrial Average i francuski CAC40 indeks, koristeći dnevne podatke u razdoblju 1999. do 2012. godine. U svom radu koriste multivarijatnu frakcijsku kointegraciju i c-DCC-FIAPARCH model, te zaključuju kako u dugom roku tržišta nafte i tržišta dionica konvergiraju istom ekvilibrijumu. Također dolaze do zaključka kako veza između varijabli varira kroz vrijeme ovisno o tome kakvi se ekonomski šokovi događaju, odnosno jesu li uzrokovani sa potražne ili ponudne strane.

Ogiri et al. (2013.) u svom radu istražuju vezu nafte i tržišta kapitala, koje je predstavljeno kroz broj tvrtki izlistanih na burzi, tržišnoj kapitalizaciji i kretanje cijena dionica. U svom radu koriste Johansonov test kointegracije, ADF i VEC testove, te VAR model. Na temelju dobivenih rezultata zaključuju kako postoji veza između performansa dionica i nafte.

Wang i Zhou (2013.) istražuju utjecaj promjena cijena nafte na različite makroekonomske varijable. Oni zaključiju kako promjene cijena nafte imaju značajan utjecaj na dionička tržišta, inflaciju i cijenu zlata, te u kratkom roku na kamatne stope. Na temelju Grangerova testa zaključuju kako postoji cijena nafte, cijena zlata i indeksi dioničkih tržišta utječu jedni na druge, te da među njima postoji kauzalnost (Slika 3.). Utvrđena je negativna veza između cijena nafte i burzovnih indeksa, dok ostale varijable imaju pozitivnu vezu.

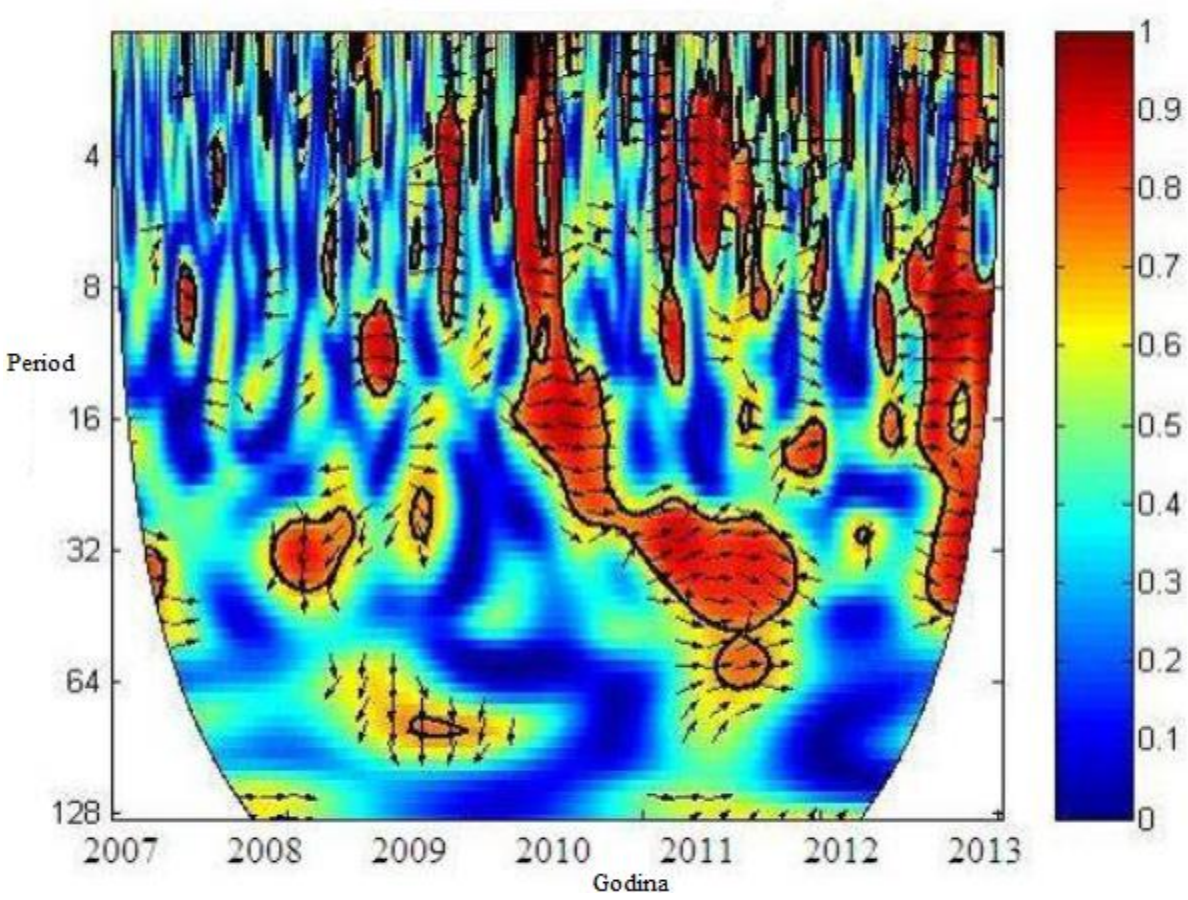
Pairwise Granger Causality Tests
Date: 10/11/12 Time: 01:59
Sample: 1973Q2 2012Q1
Lags: 2

Null Hypothesis:	Obs	F-Statistic	Prob.
LOIL does not Granger Cause LGOLD	154	1.52971	0.2200
LGOLD does not Granger Cause LOIL		1.50333	0.2257
LDJX does not Granger Cause LGOLD	154	0.46890	0.6266
LGOLD does not Granger Cause LDJX		0.52374	0.5934
LDJX does not Granger Cause LOIL	154	1.54981	0.2157
LOIL does not Granger Cause LDJX		0.51533	0.5984

Slika 3: Test Grangerove kauzalnosti

Izvor:Wang i Zhou (2013.)

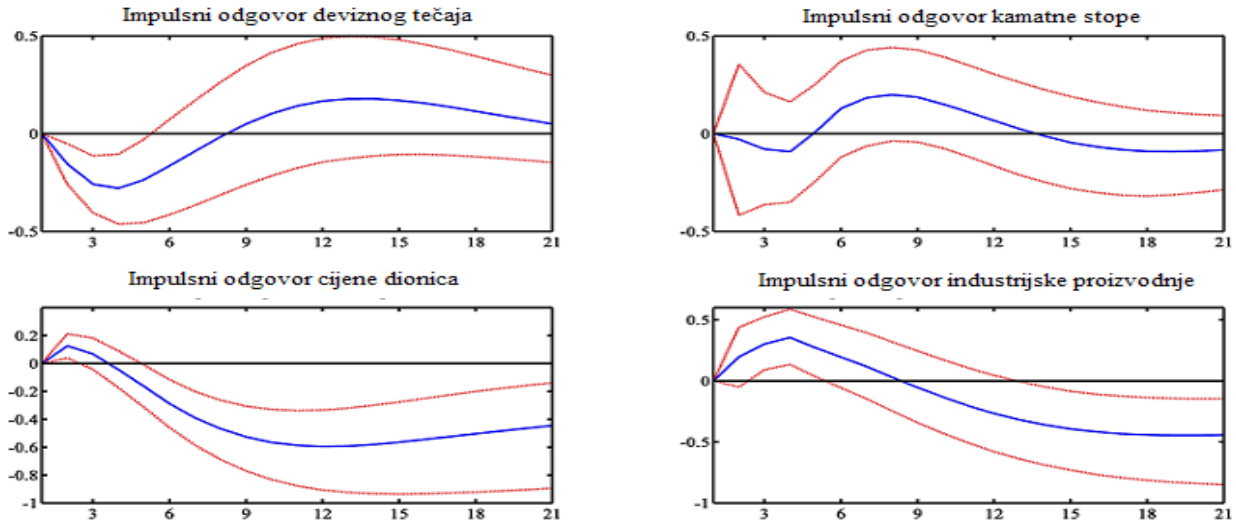
Shafai i Masih (2015.) koriste „wavelet“ analizu kako bi pokazali kada i koliko se vremenske serije zajedno pomiču. Na osi y prikazana je frekvencija, a na osi x vrijeme. Boja pojedinih područja pokazuje zajedničko kretanje, plava znači da ga nema, dok kako se kreće spektar prema crvenom, odnosno crnom zajedničko kretanje nafte i indeksa je veće. Primjerice indeks S&P500 se nije značajnije kretao u skladu sa cijenom nafte do 2009. godine, kada se počima kretati, te u narednom razdoblju može se vidjeti više epizoda zajedničkog kretanja pri višim frekvencijama (Slika 4.).



Slika 4: Wavelet -S&P500 kretanje sa cijenom nafte

Izvor: Shafaai i Masih (2015.)

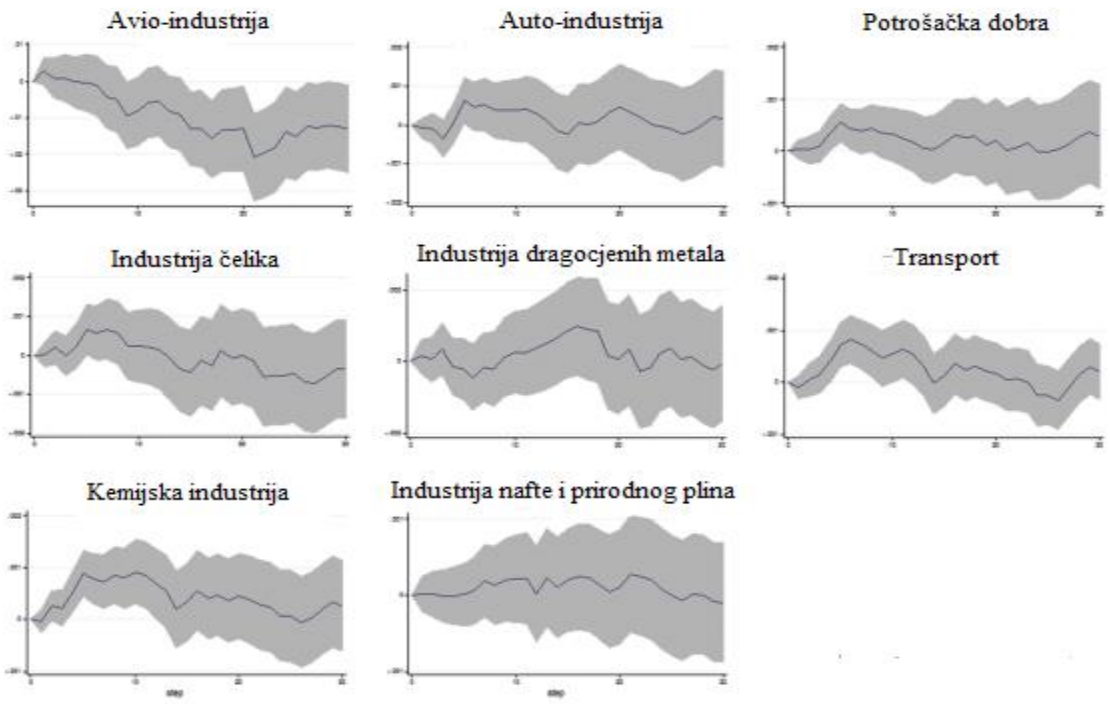
Ahmed i Naser (2016.) pomoću FAVAR modela ispituju utjecaj naftnih šokova na tržišta dionica Brazila, Rusije, Kine i Indije. Dionička tržišta Brazila i Indije reagiraju negativno na naftne šokove, dok Kina pozitivno reagira, uz napomenu da kinesko tržište u magnitudi reakcije je najslabije. Rusko tržište dionica na početku pozitivno reagira, no nakon četiri mjeseca ipak se mijenja reakcija u negativnu. Negativan odgovor ruskog tržišta na naftni šok doseže svoj vrh otprilike nakon godinu dana od početka šoka. U slučaju Rusije utjecaj naftnog šoka na devizni tečaj je negativan, no nakon osam mjeseci utjecaj nestaje. Kamatne stope u Rusiji negativno reagiraju u početku naftnog šoka, ali se kasnije utjecaj okreće u pozitivan. Promjena cijene nafte na industrijsku proizvodnju u Rusiji u početku ima pozitivan utjecaj, no kasnije se javlja i negativan što upućuje kako se utjecaji mijenjaju tokom vremena (Slika 5.).



Slika 5: Impulsni odgovor burzovnog indeksa i ostalih varijabli na naftni šok, Rusija

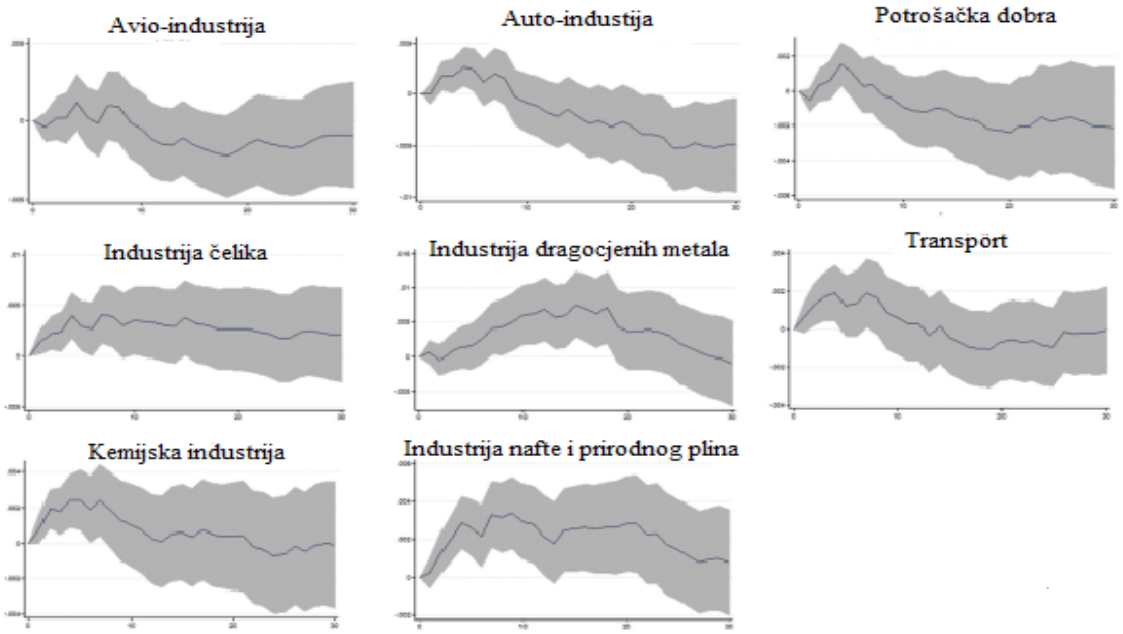
Izvor: Ahmed i Naser (2016.)

Ahmadi et al. (2016.) istražuju utjecaj naftnih šokova na agregatne cijene dionica SVAR modelom, kao i na različite industrije. Prema istraživanju šokovi uzrokovani potražnjom za naftom imaju najveći utjecaj na kretanja agregatnih povrata na tržištu kapitala. Slika 6. pokazuje kako negativni šokovi potražnje utječu na industrije, iz čega možemo zaključiti kako postoji negativna veza između varijabli. Prema rezultatima istraživanja po industrijama, sve industrije u slučaju globalnog šoka potražnje apreciraju (Slika 7.). Potonju tezu autori objašnjavaju time što porastom potražnje za naftom (rast cijene) raste i realna ekonomska aktivnost koja ujedno gura i potražnju za proizvodima ostalih industrija. Nakon određenog perioda vidimo kako se povrat u većini industrija spušta na pred-šokovne razine zbog toga što u dužem periodu više cijene nafte smanjuju agregatnu realnu ekonomsku aktivnost. Na slici 8. može se vidjeti kako pozitivan šok špekulativne potražnje za naftom utječe negativno na tržišta dionica s iznimkom dionica iz industrije nafte i industrije dragocjenih metala, ali sa određenom odgodom efekta.



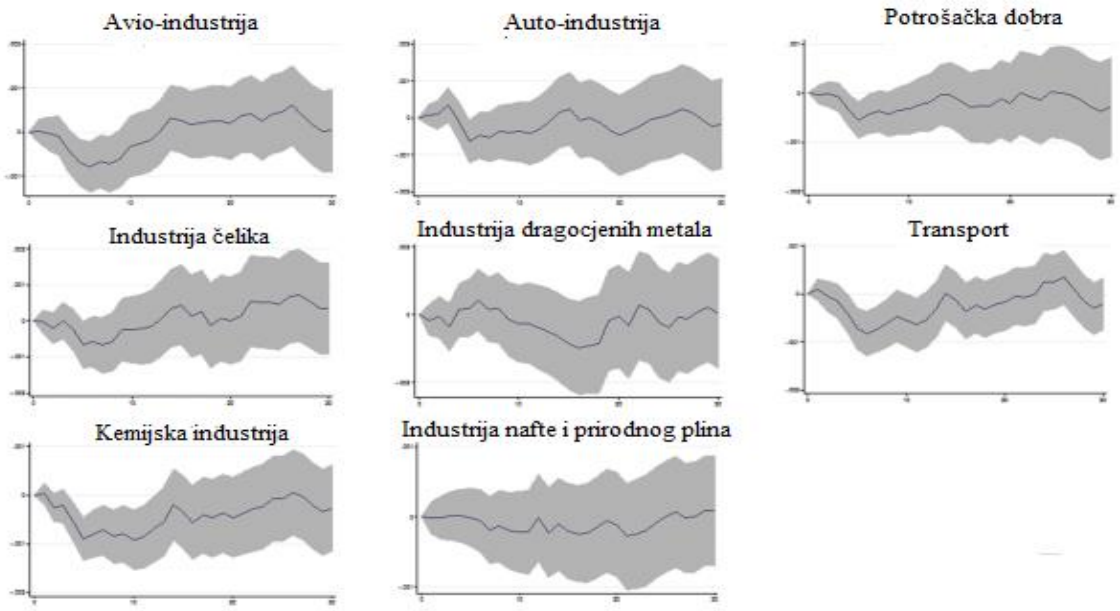
Slika 6: Impulsni odgovor izabranih industrija na naftni šok ponude

Izvor: Ahmadi et al. (2016.)



Slika 7: Impulsni odgovor izabranih industrija na naftni šok potražnje

Izvor: Ahmadi et al. (2016.)



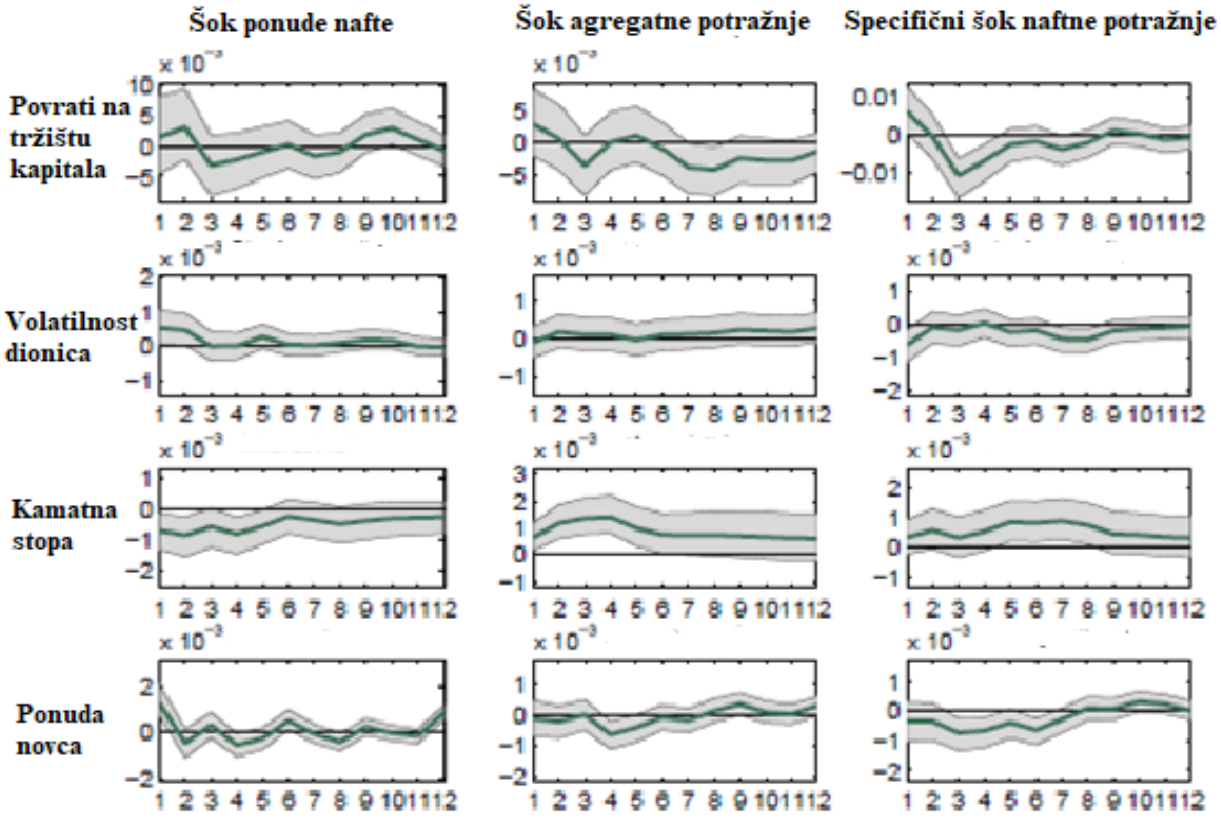
Slika 8: Impulsni odgovor izabranih industrija na naftni šok špekulativne potražnje

Izvor: Ahmadi et al. (2016.)

Wei i Guo (2017.) kroz svoje istraživanje zaključuju da je veza između kineskog tržišta dionica i cijene nafte nestabilna. Prema njihovim rezultatima promjene cijena nafte imaju veći utjecaj povrate na tržištu kapitala, nego li na volatilnosti tržišta kapitala. Na slici 9. može se vidjeti kako da je odgovor povrata na tržištu kapitala na šokove ponude i potražnje sličan, te da nemaju značajnijeg utjecaja na promatranu varijablu, za razliku specifičnih šokova potražnje čiji je utjecaj vidljiv u trećem i četvrtom mjesecu. Prema prethodno navedenom autori zaključuju kako su ti šokovi povezani sa špekulativnom potražnjom. Utjecaj sve tri vrste šokova na volatilnost na tržištu kapitala je nezamjetan, dok na kamatne stope varira tokom vremena. Ponuda novca nema ujednačen odgovor na različite šokove, te se povećava na šok ponude, dok u druga dva slučaja reagira u suprotnom smjeru.

Wang et al. (2013.) istražuju utjecaj promjena cijena nafte na različite ekonomije u ovisnosti jesu li one neto uvoznici ili izvoznici nafte. Prema autorima kretanje cijene nafte može objasniti 20%-30% ukupnih varijacija na tržištu dionica, te je njen utjecaj jači u zemljama koje su neto izvoznici, nego li neto uvoznici, zbog toga što je prema njima ovisnost o nafti bitnija za ekonomije zemalja izvoznika. Ako se dogodi pad ekonomske aktivnosti, te se smanji potražnja za naftom, a time i njena cijena, protokom vremena dogoditi će se smanjenje industrijskih

troškova u zemljama uvoznicama što će privremeno neutralizirati negativne utjecaje poslovne nesigurnosti i utjecati na vrijednost kompanija. U istom slučaju kod zemalja neto izvoznica smanjena potražnja će rezultirati manjim prihodima zemalja uvoznica što će se odraziti na dionice poduzeća koja kotiraju na burzama. Šokovi u ponudi i kretanje cijena nafte uzrokovano promjenama količina utječu negativno na oba tipa zemalja.

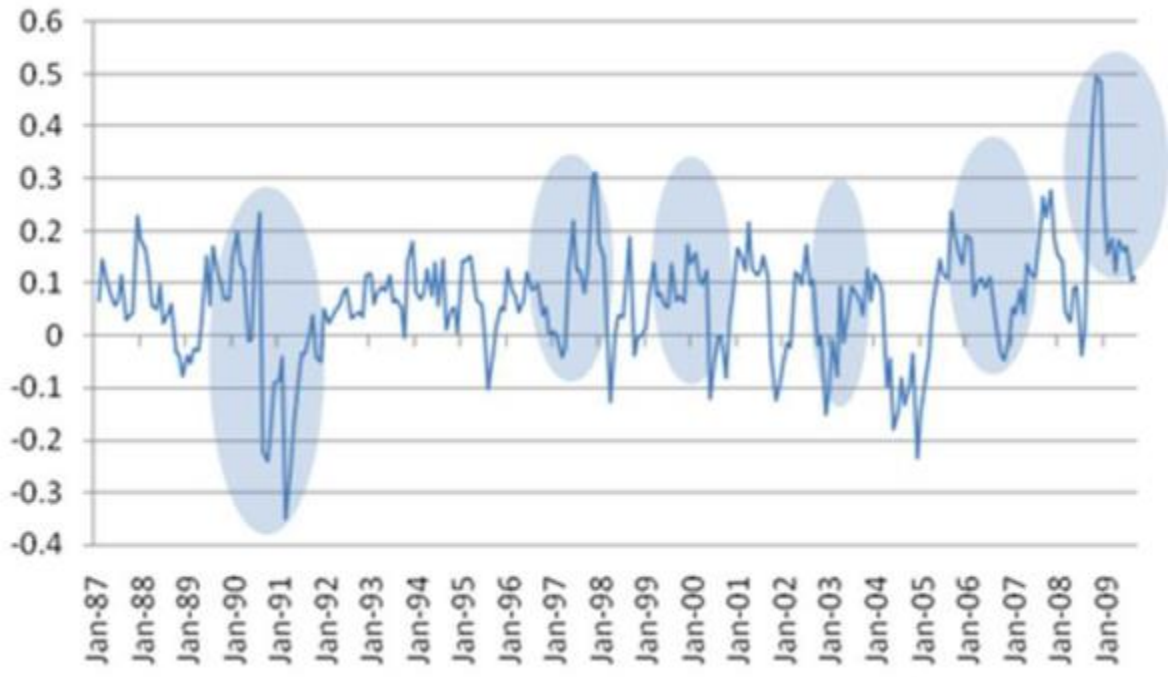


Slika 9: Impulsni odgovor izabranih industrija na naftne šokove, Kina

Izvor: Wei i Guo (2017.)

Aydogan et al. (2017.) dolaze do rezultata koji ukazuju da je korelacija između nafte i cijena dionica izraženija kod zemalja uvoznica, nego li zemalja izvoznica. Navode kako je najveća korelacija kod zemalja uvoznica u slučaju Ujedinjenog kraljevstva i Nizozemske, 43,2% i 39,7%. Za usporedbu, najveća korelacija kod zemalja izvoznica, je navedena Kanada i Saudijska Arabija sa vrijednostima, 53,6% i 22,8%. Također autori zaključuju kako je veća korelacija kod zemalja poput SAD-a, Ujedinjenog kraljevstva, Nizzozemske, Kanade i Norveške, nego li kod zemalja euro područja, Japana i zemalja u razvoju.

Degiannakis et al. (2011.) uz pomoć DCC-GARCH-GJR pristupa analiziraju vezu između nafte i različitih dioničkih indeksa zemalja koje su neto uvoznice i izvoznice nafte. Prema rezultatima vremenski varirajuća korelacija cijena nafte i cijena dionica se ne razlikuje za neto uvoznice i izvoznice nafte. Navedeno autori objašnjavaju činjenicom da su šokovi agregatne potražnje uzrokovani fluktuacijama u globalnim poslovnim ciklusima i očekivanje je da će pogoditi tržišta na sličan način. Činjenicu da su šokovi špekulativne potražnje sličnog efekta na uvoznice i izvoznice autori objašnjavaju time da je naftni sektor u zemljama uvoznicama malen, te da bi bilo kakva nesigurnost u budućoj ponudi nafte, u obzir uzimajući buduću potražnju, bila minimalna. Ipak prema autorima veliki događaji poput ratova ili terorizma mogu utjecati na korelaciju između promatranih varijabli. Autori tvrde kako šokovi ponude nemaju utjecaja na vezu među cijene nafte i tržišta dionica. Na slici 10. prikazana je vremenski zavisna korelacija između DAX indeksa i cijena nafte.



Slika 10: vremenski zavisna korelacija između njemačkog DAX indeksa i cijena nafte

Izvor: Degiannakis et al. (2011.)

Prije navedeni autori, primjenjujući različite pristupe u analizama, dolaze do rezultata koji ukazuju na postojanje veze između tržišta nafte i tržišta kapitala. Također pojedini autori razlikuju tri vrste šokova, šokovi ponude, potražnje i špekulatuivne potražnje za naftom, te analiziraju njihov utjecaj na burzovne indekse. Prema rezultatima prije navedenih istraživanja, može se zaključiti kako postoji teorijska veza između tržišta nafte i tržišta kapitala, temeljem čega će se daljnje istraživanje razvijati.

2.4. TRŽIŠTE DIONICA I ZNAČAJ NAFTE ZA IZABRANE ZEMLJE

Energija predstavlja glavni input, posredno ili neposredno, u proizvodnji dobara i usluga. Ona spada u primarne resurse, te su njezina dostupnost i cijena jedne od glavnih determinanti u određivanju i modeliranju različitih vrsta proizvodnje. Dostupnost energije u različitim oblicima može predstvljati bitnu odrednicu u odabiru mjesta i vrste proizvodnje ili pružanja usluge. Cijena energije jako je bitna za kompanije kojima troškovi mogu znatno varirati ovisno o kretanju na tržištima. Povećanje cijena može utjecati na troškove kompanija što posljedično ima utjecaja na njihovu profitabilnost, financijske rezultate i percepciju investitora o njihovoj vrijednosti.

Sirova nafta predstavlja jedan od glavnih izvora energije i kretanje njene cijene ima znatnog utjecaja na ulagačku politiku poduzeća i ulagačke politike investitora na tržištima kapitala gdje kotiraju financijski instrumenti izdani od strane tih poduzeća. Iz sirove nafte dalje se dobivaju različite vrste goriva, kao i ostali proizvodi koji sudjeluju u proizvodnom lancu, primjerice polietileni koji se koriste u proizvodnji različitih plastičnih masa. Nafta je ograničen resurs koji se ne može pronaći svugdje, te predstavlja jednu od glavnih prednosti za države koje je imaju i mogu koristiti. Zemlje koje nemaju naftu prisiljene su ju uvoziti i time u mnogome ovise o njenoj vrijednosti. Kroz povijest nafta se koristila u manjim količinama do 19. stoljeća i industrijske revolucije, kada je i počela njena veća eksploatacija. Cijene nafte, kako je već prije iznešeno, ne utječu samo na kompanije, već utječu i na mnoge druge varijable, industrijsku aktivnost, inflaciju, devizni tečaj i dr.

U tablici 2. može se vidjeti uvoz energije (ekvivalentno tisućama tona nafte) po zemljama u 2015. godini u Europskoj uniji kao i pojedinim zemljama članicama. Iz slike je vidljivo kako je

od zemalja uvoznica koje ćemo promatrati u ekonometrijskoj analizi najveći uvoznik Njemačka, koju slijede Italija, Francuska, Austrija, Hrvatska i Slovenija. Kada se podatci gledaju po stanovniku, tada je i dalje prva Njemačka, ali iza nje dolazi Austrija, te Slovenija i Hrvatska mijenjaju mjesto u poretku. Norveška prema izvorima Europske komisije ima neto izvoz u 2015. godini u apsolutnom iznosu od 177 067 tisuća tona, odnosno 34,1 tonu po stanovniku.

U tablici 3. može se vidjeti kako je u slučaju nafte najveći uvoznik nafte, relativno u 2015. godini, Slovenija sa 100%, koju slijede Francuska (98%), Njemačka (96%), Austrija (94%), Italija (89%) i Hrvatska (80%). Također može se vidjeti kako Norveška ima -682% uvoza, odnosno, Norveška ima izvoz skoro sedam puta veći od vlastitih potreba za naftom. Rusija prema „Američkoj agenciji za informacije o energiji“ (EIA) izvozi oko 70% svoje proizvodnje nafte i naftnih prerađevina. Većinu nafte izvozi na eurposko tržište (poglavito zemlje članice OECD-a), zatim na azijsko-pacifičko tržište, te manji dio u SAD i druge zemlje (Slika 11.).

Tablica 2: Neto uvoz primarnih oblika energije, ekvivalent tisućama tona nafte, 2005.-2015.

	Ekvivalentno tisućama tona nafte						Ekvivalentno tisućama tona nafte po stanovniku					
	2005	2007	2009	2011	2013	2015	2005	2007	2009	2011	2013	2015
EU-28 (*)	980,186	983,658	936,433	943,563	908,012	902,124	2.0	2.0	1.9	1.9	1.8	1.8
Belgija (**)	53,428	50,935	48,125	48,077	48,571	50,625	5.1	4.8	4.5	4.4	4.3	4.5
Bugarska	9,276	10,180	7,981	6,911	6,357	6,585	1.2	1.3	1.1	0.9	0.9	0.9
Češka	12,638	11,617	11,558	12,605	12,050	13,544	1.2	1.1	1.1	1.2	1.1	1.3
Danska	-10,126	-5,199	-3,835	-1,072	2,249	2,301	-1.9	-1.0	-0.7	-0.2	0.4	0.4
Njemačka (**)	208,193	196,730	195,394	197,139	204,888	196,015	2.5	2.4	2.4	2.5	2.5	2.4
Estonija (**)	1,496	1,576	1,227	761	848	483	1.1	1.2	0.9	0.6	0.6	0.4
Irska (***)	13,765	14,048	13,296	12,566	12,357	12,716	3.3	3.2	2.9	2.7	2.7	2.7
Grčka	23,498	24,715	22,353	19,874	16,390	18,812	2.1	2.2	2.0	1.8	1.5	1.7
Španjolska	123,832	123,159	110,057	104,579	89,047	94,428	2.8	2.7	2.4	2.2	1.9	2.0
Francuska (**)	143,957	137,223	133,211	126,898	125,317	116,843	2.3	2.1	2.1	1.9	1.9	1.8
Hrvatska	5,147	5,237	4,381	4,604	4,039	4,166	1.2	1.2	1.0	1.1	0.9	1.0
Italija	160,365	158,158	142,354	142,439	124,235	121,831	2.8	2.7	2.4	2.4	2.1	2.0
Cipar	2,843	2,899	2,920	2,665	2,333	2,452	3.8	3.8	3.6	3.1	2.7	2.9
Latvija	3,097	3,162	2,886	2,747	2,628	2,370	1.4	1.4	1.3	1.3	1.3	1.2
Litva	5,026	5,776	4,291	5,839	5,304	5,482	1.5	1.8	1.4	1.9	1.8	1.9
Luksemburg (****)	4,675	4,478	4,255	4,442	4,210	4,007	10.1	9.3	8.5	8.6	7.7	7.0
Mađarska (****)	17,421	16,417	14,722	12,974	11,879	13,454	1.7	1.6	1.5	1.3	1.2	1.4
Malta	1,630	1,811	2,001	2,300	2,138	2,230	4.0	4.5	4.9	5.5	5.0	5.2
Nizozemska	37,577	37,689	34,491	28,432	24,248	46,785	2.3	2.3	2.1	1.7	1.4	2.8
Austrija	24,520	23,408	21,079	23,417	20,781	20,214	3.0	2.8	2.5	2.8	2.5	2.3
Poljska	15,938	24,755	29,943	33,695	25,166	28,021	0.4	0.6	0.8	0.9	0.7	0.7
Portugal	24,845	21,718	20,779	18,783	16,662	18,300	2.4	2.1	2.0	1.8	1.6	1.8
Rumunjska	10,840	12,835	7,224	7,896	6,019	5,541	0.5	0.6	0.4	0.4	0.3	0.3
Slovenija (*****)	3,855	3,874	3,460	3,512	3,250	3,233	1.9	1.9	1.7	1.7	1.6	1.6

Slovačka	12,428	12,200	11,149	11,176	10,066	9,642	2.3	2.3	2.1	2.1	1.9	1.8
Finska	18,935	19,951	18,326	19,026	16,646	15,660	3.6	3.8	3.4	3.5	3.1	2.9
Švedska	19,460	18,281	17,499	18,596	16,020	14,240	2.2	2.0	1.9	2.0	1.7	1.5
Ujedinjeno Kraljevstvo	31,610	46,035	55,336	72,683	94,316	72,194	0.5	0.8	0.9	1.1	1.5	1.1
Island	1,070	1,132	1,177	1,135	810	961	3.6	3.6	3.7	3.6	2.5	2.9
Norveška	- 195,956	- 188,179	- 186,599	- 170,173	- 160,473	- 177,067	-42.4	-40.0	-38.6	-34.4	-31.6	-34.1
Crna Gora	436	641	413	41	233	306	0.7	1.0	0.7	0.7	0.4	0.5
Makedonija	1,199	1,401	1,211	1,376	1,300	1,420	0.6	0.7	0.6	0.7	0.6	0.7
Albanija	1,119	1,026	1,025	834	670	282	0.4	0.3				0.1
Srbija	5,536	5,933	4,901	4,930	3,536	4,009	0.7	0.8	0.7	0.7	0.5	0.6
Turska	62,035	75,967	70,633	80,543	87,415	102,791	0.9	1.1	1.0	1.1	1.1	1.3
Kosovo (******)	550	595	636	700	506	697	0.3	0.3	0.3			

(*) Tona nafte ekvivalentno po stanovniku, 2009., 2011., 2013. I 2015.: prekid u serijama

(**) Tona nafte ekvivalentno po stanovniku, 2011. I 2015.: prekid u serijama

(***) Tona nafte ekvivalentno po stanovniku, 2015.: prekid u serijama

(****) Tona nafte ekvivalentno po stanovniku, 2011.: prekid u serijama

(*****) Tona nafte ekvivalentno po stanovniku, 2007.: prekid u serijama

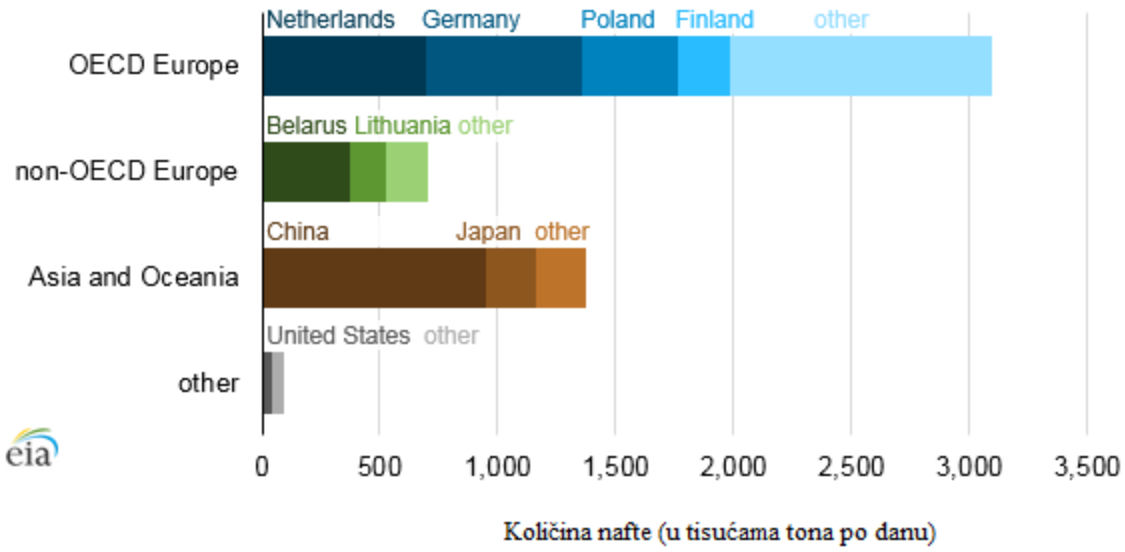
(******) Ova oznaka ne utječe na stajališta o statusu i koja je u skladu sa UNSCR 1244/1999 i mišljenjem ICJo Kosovskoj deklaraciji o nezavisnosti Tona nafte ekvivalentno po stanovniku, 2011.: prekid u serijama

Izvor: EC , http://ec.europa.eu/eurostat/statisticsexplained/images/e/e5/Net_imports_of_primary_energy%2C_2005-2015_YB17.png, pristupljeno na datum 30.03.2018.

Tablica 3: Neto uvoz nafte 1990.-2015.

	1990	1995	2000	2005	2010	2015
EU-28	80	74	76	82	84	89
EA-19	96	96	98	97	97	98
Belgija	98	100	100	101	101	104
Bugarska	88	100	95	102	101	99
Češka	95	98	95	97	97	98
Danska	30	11	-81	-103	-43	6
Njemačka	94	96	95	97	97	96
Estonija	100	80	77	71	57	39
Irska	104	100	99	100	97	104
Grčka	93	98	100	98	99	105
Španjolska	99	101	101	101	100	102
Francuska	96	97	99	99	98	98
Hrvatska	43	56	61	79	80	80
Italija	97	93	96	92	94	89
Cipar	99	103	100	102	104	103
Latvija	100	103	95	102	94	103
Litva	104	114	100	92	99	101
Luksemburg	101	98	102	99	99	99
Mađarska	75	71	76	81	85	93
Malta	100	105	100	100	99	98
Nizozemska	88	86	97	96	94	102
Austrija	90	89	89	92	90	94
Poljska	105	96	99	98	97	97
Portugal	101	101	99	102	98	100
Rumunjska	60	49	34	39	52	53
Slovenija	103	98	102	101	99	100
Slovačka	100	101	90	88	90	89
Finska	100	95	103	98	89	105
Švedska	100	96	101	104	94	105
Ujedinjeno Kraljevstvo	-13	-57	-55	-3	14	36
Island	100	100	104	102	97	103
Norveška	-813	-1502	-1545	-1126	-627	-682
Crna Gora				100	100	98
Makedonija	100	117	97	102	98	100
Albanija	1	16	72	74	51	7
Srbija	80	45	33	85	75	63
Turska	89	92	93	91	92	97
Bosna i Hercegovina						
Kosovo			100	100	100	100

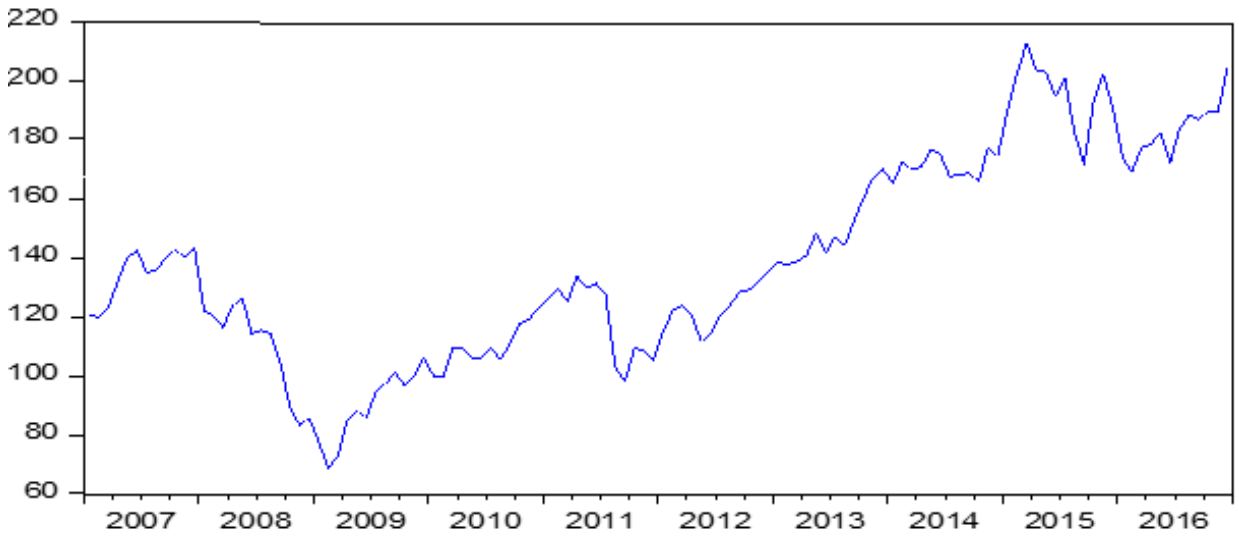
Izvor: EC, http://ec.europa.eu/eurostat/statistics-explained/images/8/87/Oil_import_dependency%2C_1990-2015%2C_percentage_update.png, pristupljeno na datum 30.03.2018.



Slika 11: Neto izvoz bafte iz Rusije u 2016. godini

Izvor: EIA, https://www.eia.gov/todayinenergy/detail.php?id=33732, pristupljeno na datum 04.04.2018.

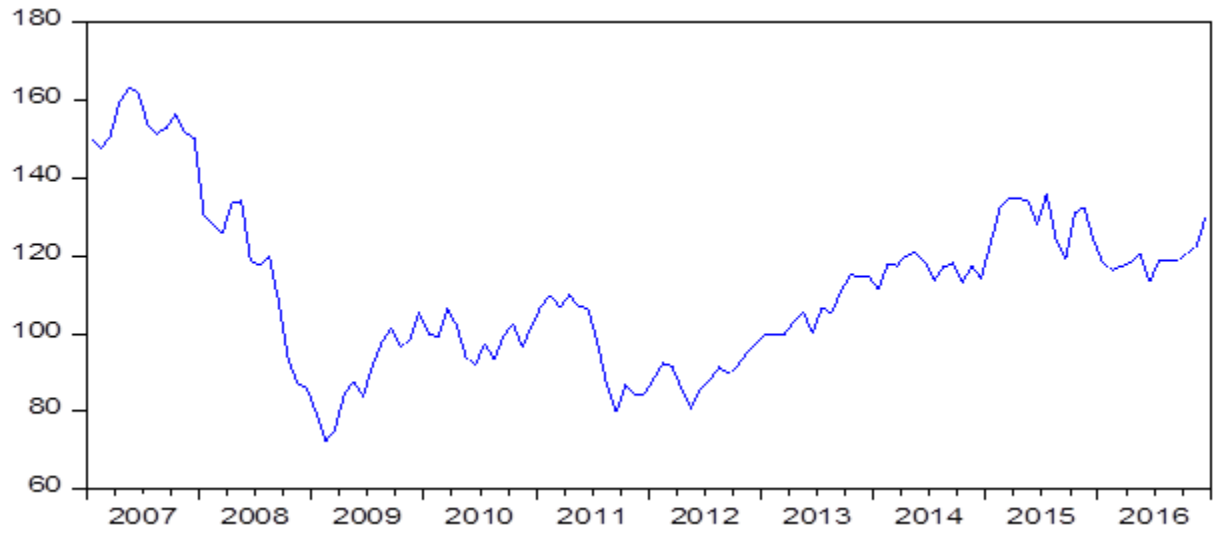
Financijski centar njemačkog tržišta kapitala nalazi se u Frankfurtu na Majni gdje se trguje većinom vrijednosnih papira izdanih u Njemačkoj, ali i veliki dio europskog prometa prolazi kroz ovu burzu. Osnovni njemački burzovni index je DAX, čije različite varijante postoje poput TecDAX, MDAX, SDAX, DivDAX. DAX indeks čine neke od najpozantijih njemačkih kompanija poput: Adidas, Allianz, Bayer, BMW, Daimler, Deutche bank, Henkel, Lufthansa, Simens, Volkswagen, Frankfurtska burza (2018.). Na grafikonu 2. može se vidjeti indeksirano kretanje indeksa DAX (2010, siječanj =100) od 2007. godine do kraja 2016. godine.



Grafikon 2: Kretanje DAX indeksa 2007.-2016. godine

Izvor: Izrada autora prema podacima preuzetim sa: https://www.investing.com/indices/world-indices., pristupljeno na datum 05.03.2018.

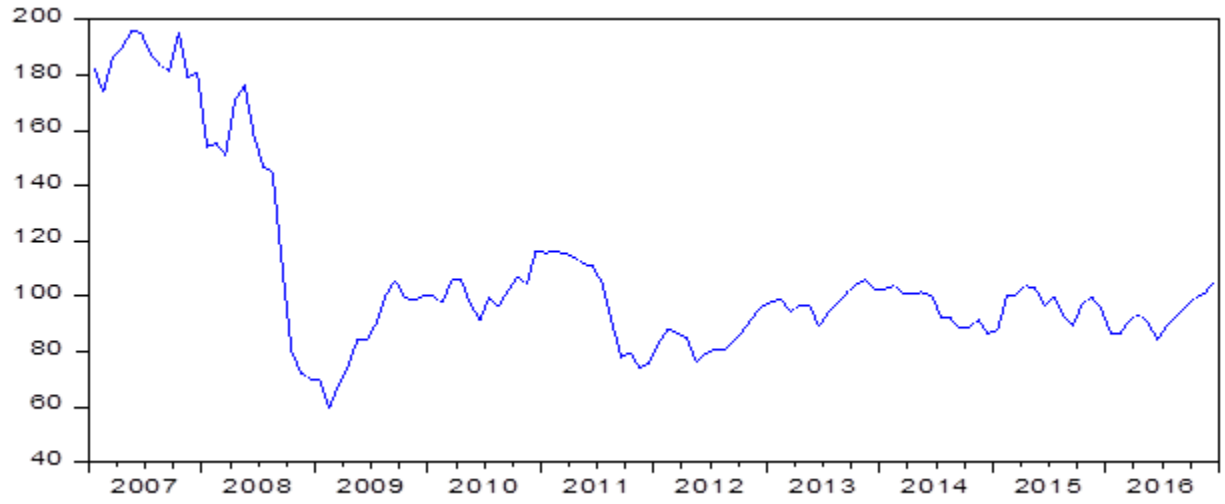
Nekadašnja Pariška burza 2000. godine spojila se sa još tri europske burze, Amsterdamskom, Brusselskom i Lisabonskom, te je nastao Euronext (EURONEXT (2018.)), druga najveća burza vrijednosnica u Europi, nakon Londonske burze. Glavni index burze Euronext Pariz je CAC40 koji je sačinjen od 40 najvećih i najtrgovanijih kompanija na toj burzi. Index je u uporabi od 1987. godine, kada mu je početna vrijednost bila 1000 poena. Neke od napozantijih kompanija koje čine ovaj index su: Airbus, BNP Paribas, Credit Agricole, L'Oreal, Orange, Michelin, Peugeot, Renault, Total i dr. Najveći udio u indeksu imaju kompanije koje se bave proizvodnjom industrijskih dobara i usluga, nafte i plina, te banke. Kretanje prvih dviju skupina bi trebalo biti dijelom određeno i kretanjima cijena nafte čime se bavimo u ovom radu. Kretanje indeksiranog indeksa CAC40 (2010, siječanj=100) prikazano je u razdoblju 2007. do 2016. godine (Grafikon 3.)



Grafikon 3: Kretanje CAC40 indeksa 2007.-2016. godine

Izvor: Izrada autora, prema podacima preuzetim sa: https://www.investing.com/indices/world-indices, pristupljeno na datum 05.03.2018.

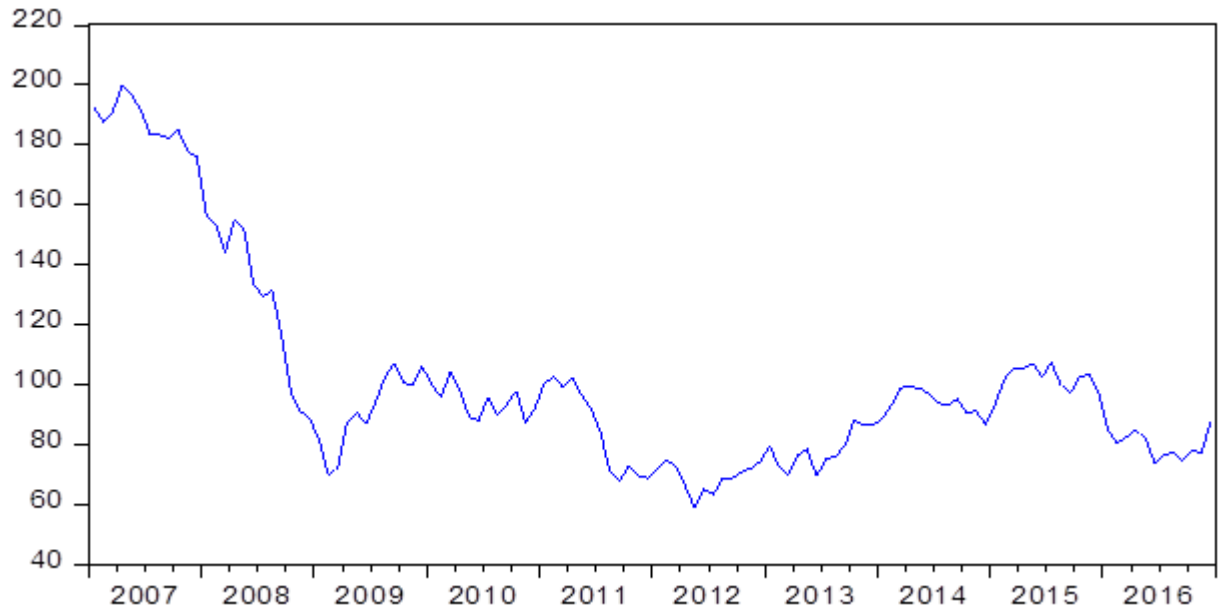
Austrijsko tržište kapitala i austrijska burza predstavlja jedno od glavnih tržišta ove vrste u srednjoj i istočnoj Europi. Glavni i vodeći indeks na austijskoj burzi je ATX koji se sastoji iz 20 različitih dionica (Bečka burza, 2018.)). Neke od najpozantijih kompanija koje sačinjavaju ovaj indeks su Erste i Raiffeisen banka, OMV, Austrijska pošta i Austrijski telekom. Činjenica da OMV, austrijska naftna kompanija, teži oko 15% indeksa nam je zanimljiva zbog toga što će se u ovom radu ispitivati utjecaj cijena nafte na sam indeks. Ostali indeksi ove burze su ATX PRIME, ATX FIVE, IATX i WBI index. Na grafikonu 4. prikazano je povijesno indeksirano kretanje ATX indeksa (2010, siječanj=100).



Grafikon 4: Kretanje ATX indeksa 2007.-2016. godine

Izvor: Izrada autora prema podacima preuzetim sa: https://www.investing.com/indices/world-indices, pristupljeno na datum 05.03.2018.

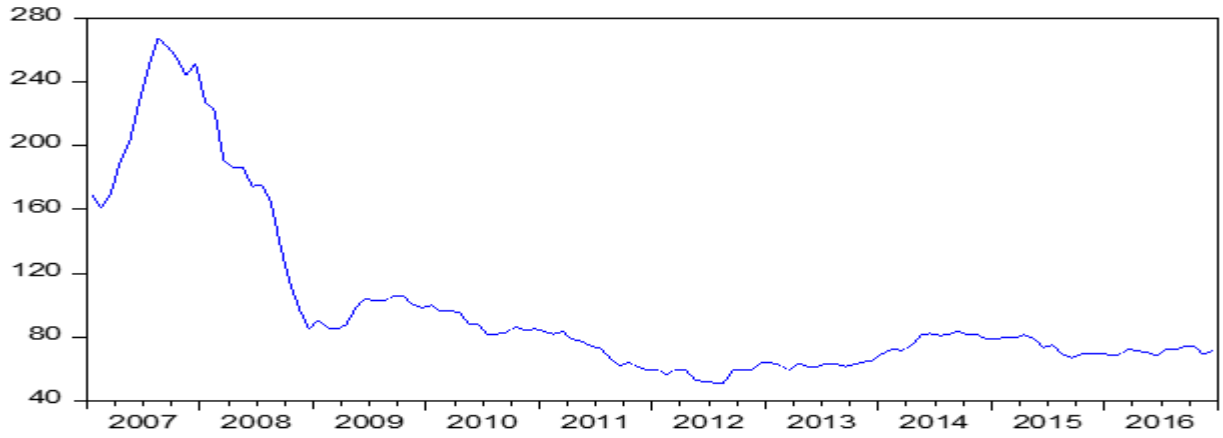
Talijanska burza danas posluje u sklopu „London Stock Exchange“ grupe, te joj je sjedište u Milanu. Vodeći indeks na talijanskoj burzi je FTSE MIB indeks, koji se mjeri od 1997. godine (Talijanska burza (2018.)). Kompanije koje čine ovaj indeks, vezane direktno uz naftu su naftne kompanije Eni, Italgas, Saipem i Snam. Također kompanije iz automobilske industrije su Brembo, Ferrari, Fiat Chrysler i Pirelli, također u sastav indeksa ulaze i različite kompanije iz sektora energetike, proizvodnje industrijskih dobara i pružatelja financijskih usluga. Na grafikonu 5. prikazano je indeksirano kretanje FTSE MIB indeksa (2010, siječanj=100).



Grafikon 5: Kretanje FTSE-MIB indeksa 2007.-2016. godine

Izvor: Izrada autora prema podacima preuzetim sa: https://www.investing.com/indices/world-indices, pristupljeno na datum 05.03.2018.

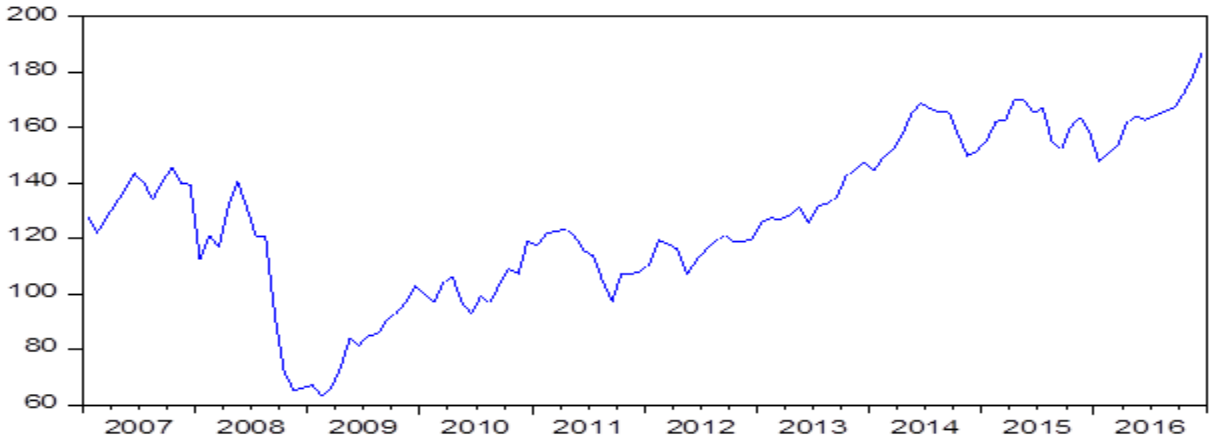
Slovenska burza osnovana je 1989. godine pod nazivom „Ljubljanska burza“. Od 2015. godine vlasnik burze u Sloveniji je Zagrebačka burza. Indeks na ovoj burzi je SBITOP, a čine ga najtrgovanije slovenske kompanije poput: Krke, Petrola, osiguranja Triglav i Sava, Telekom Slovenije, Cinkare Celje, Gorenja, Uniora, Intereurope i KD Grupe (Burza u Ljubljani (2018.)). Među navedenim kompanijama Petrol predstavlja jedinu naftnu kompaniju, ali primjerice Intereuropa se bavi logistikom, te i za njih značajan direktan utjecaj imaju cijene nafte. Prema javno dostupnim podatcima na službenim stranicama burze, tržišna kapitalizacija na kraju 2017. godine iznosila je 5.273.885.000 eura, a najtrgovanija dionica je bila Krka, sa udjelom od 42% u ukupnom prometu. Na grafikonu 6. prikazuje se kretanje indeksiranog indeksa SBITOP (2010, siječanj=100).



Grafikon 6: Kretanje SBITOP indeksa 2007.-2016. godine

Izvor: Izrada autora prema podacima preuzetim sa: https://www.investing.com/indices/world-indices, pristupljeno na datum 05.03.2018.

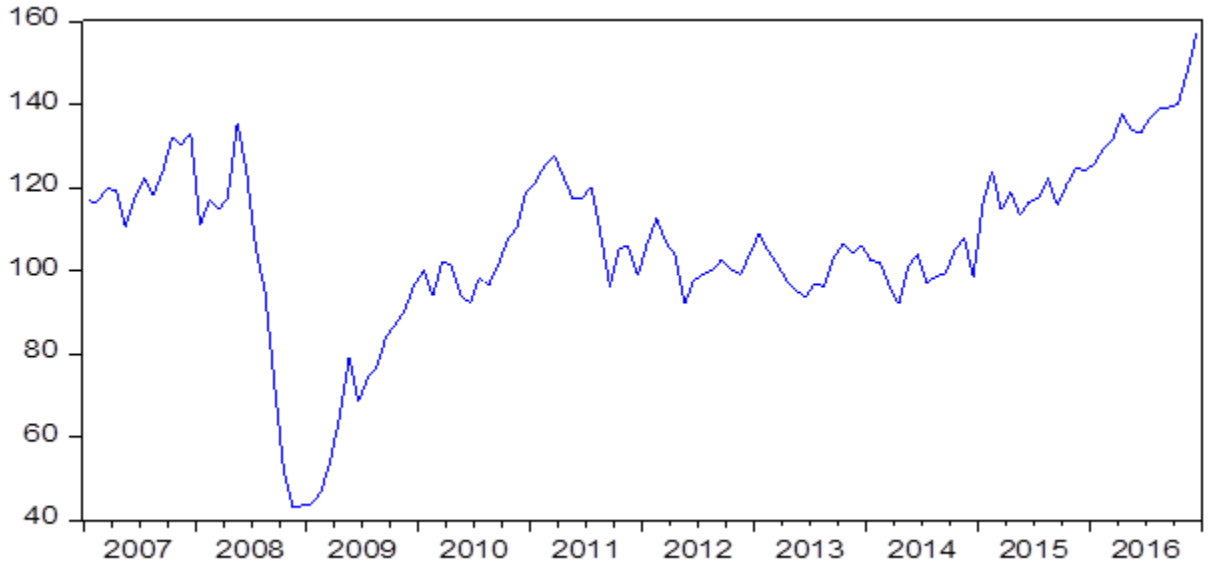
Norveška burza vrijednosnih papira nalazi se u Oslu po kojemu nosi i ime, te je osnovana u 19. stoljeću. Glavni indeks burze u Oslu je OBX indeks koji se sastoji od 25 najtrgovanijih dionica na burzi (Burza u Oslu (2018.)). Neki od glavnih sektora u kojima djeluju kompanije izlistane na burzi su energija, transport i proizvodnja morske hrane. Neke od kompanija izlistanih na burzi su Royal Caribbean Cruises i Statoil. Na grafikonu 7. prikazano je povijesno kretanje indeksiranog indeksa OBX, burze u Oslu (2010, siječanj=100).



Grafikon 7: Kretanje OBX indeksa 2007.-2016. godine

Izvor: Izrada autora prema podacima preuzetim sa: https://www.investing.com/indices/world-indices, pristupljeno na datum 05.03.2018.

Burza u Moskvi nastala je 2011. spajanjem dvije najveće reuske burze, Moscow Interbank Currency Exchange i Russian Trading System (Moskovska burza (2018.)). Na glavnom tržištu kapitala u Moskvi nalazi se preko 1400 izdanih vrijednosnih papira koje je izdalo oko 700 različitih izdavatelja. Glavni indeksi burze su MOEX (prije zvan MICEX) Russia i RTS indeks. MOEX indeks je denominiran u domaćoj valuti, rubljima, dok je RTS indeks denominiran u dolarima. Neke od glavnih komapnija koje kotiraju na burzi su Aeroflot, Gazprom, Lukoil i Rosneft, te su po svoji djelatnostima vezane uz naftu, bilo kao eksploatatori ili kao potrošači (Aeroflot). Na grafikonu 8. prikazano je kretanje indeksiranog MOEX indeksa (2010, siječanj=100).

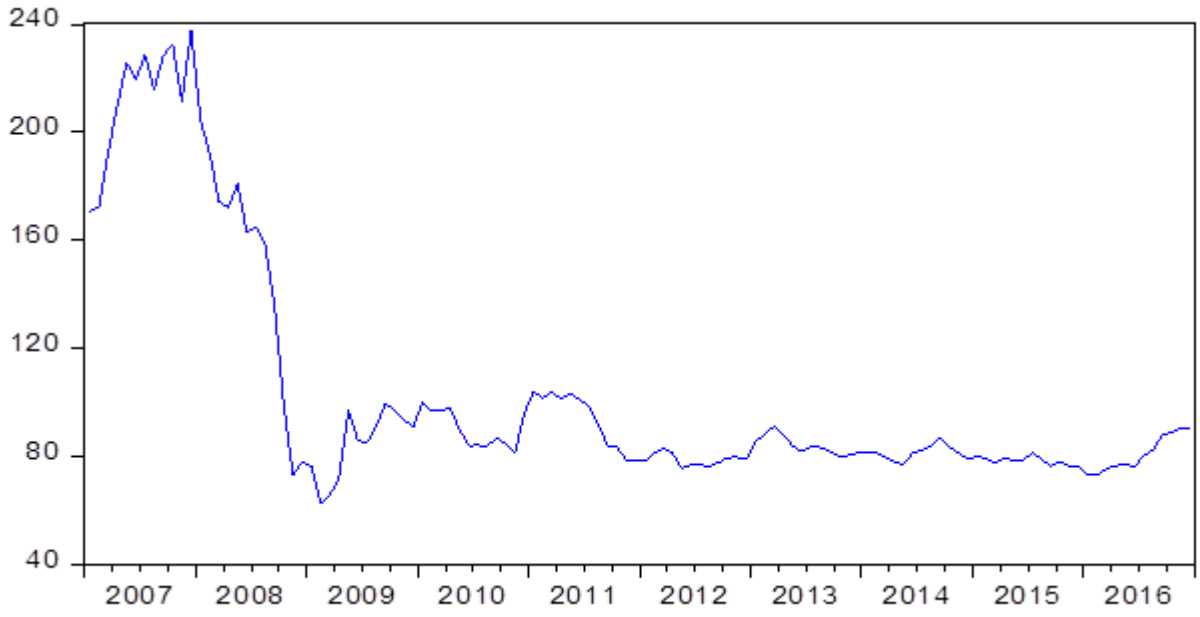


Grafikon 8: Kretanje MICEX indeksa 2007.-2016. godine

Izvor: Izrada autora prema podacima preuzetim sa: https://www.investing.com/indices/world-indices, pristupljeno na datum 05.03.2018.

Zagrebačka burza osnovana je 1991. godine, nakon demokratskih promjena (Zagrebačka burza (2018.)). Na burzi postoje dvije vrste indeksa, dionički i obveznički. Glavni dionički indeks je CROBEX, ali možemo još izdvojiti CROBEX10, CROBEXplus, CROBEXtr, CROBEXturi, CROBEXind i dr. U prosincu 2017. godine broj uvrštenih vrijednosnih papira bio je 163, od čeka 137 dionica i 26 obveznica. Tržišna kapitalizacija u prosincu iznosila je 236 milijardi kuna, od čega 138 milijardi otpada na dionice, a 98 milijardi na obveznice. Indeks CROBEX JE 2017.

godinu završio na 1842 poena. Kretanje indeksiranog CROBEX-a (2010, siječanj=100), prikazano je na grafikonu 9.



Grafikon 9: Kretanje CROBEX indeksa 2007.-2016. godine

Izvor: Izrada autora prema podacima preuzetim sa: https://www.investing.com/indices/world-indices, pristupljeno na datum 05.03.2018.

Nafta predstavlja jedan od osnovnih resursa u proizvodnji i potrošnji. Veće cijene predstavljaju veći trošak inputa i smanjenje dobiti za potrošače, te veći prihod za proizvođače. Većina burzovnih indeksa koji su ovdje nabrojeni u svom sastavu imaju kompanije koje se bave trgovinom nafte (npr. ENI, Gazprom, Statoil), te također tvrtke koje naftu koriste kao resurs. Kretanje cijena nafte ima određeni utjecaj na kretanje burzovnih indeksa, kod zemalja uvoznica i izvoznica, na čijim burzama kotiraju razne kompanije koje u većini koriste naftu kako input, ali također i kao output. Je li navedeni utjecaj jednak u svim zemljama, pronaći će se odgovor u empirijskom istraivanju prezentiranom u ovom radu.

3. REZULTATI EMPIRIJSKOG ISTRAŽIVANJA

U ovome dijelu rada, koristeći statističke i ekonometrijske metode, različite podatke se analitički obradilo kako bi se testirale hipoteze oblikovane na osnovu teorijske analize . Statističke metode su korištene kako bi se ustanovila veza između promatranih varijabli, u prvom redu cijena nafte i burzovnih indeksa, te testirala njihova veza. Ekonometrijske metode su korištene kako bi se istražila veza između varijabli modela. U ovom poglavlju prikazane su varijable i model, koji su također objašnjeni i raspravljeni kao i rezultati samog modela.

3.1. OPIS PODATAKA

U ovom radu koristili su se podatci dostupni na internet stranicama Međunarodnog monetarnog fonda, OECD-a, Administracije za energetske informacije Vlade SAD-a, Europske centralne banke i internet stranice Investing.com. Korišteni podatci su vremenske serije, u razdoblju od siječnja 2007. do prosinca 2016. godine, te predstavljaju nizove sa 120 observacija za svaku promatranu varijablu. Postupkom diferenciranja podatci su smanjeni na 119 observacija zbog prirode matematičkog procesa. Rad sadrži varijable burzovnih indeksa, cijene nafte po barelu na BRENT tržištu, indeksa potrošačkih cijena, industrijske proizvodnje, kratkoročne kamtne stope, svjetske proizvodnje nafte i tečaja nacionalne valute u odnosu na američki dolar. Sve varijable su indeksirane na siječanj 2010. kada indeks iznosi 100.

Burzovni indeksi za svih osam zemalja preuzeti su sa internetskog izvora Investing.com, te su podatci prikupljeni od stane “market makera” na pojedinim tržištima. Cijena nafte prikupljena je sa stranice Administracije za energetske informacije Vlade SAD-a, te predstavlja podatke na mjesečnoj razini. Uz promatrane podatke na stranici spomenute agencije moguće je također naći vrijednosti varijable svjetska proizvodnja nafte. Varijable indeks potrošačkih cijena i industrijska proizvodnja uzete su iz baze podataka Međunarodnog monetarnog fonda, dok je varijabla tečaja uzeta iz baze “International finance statistics” (IFS), MMF-a. Zbog ograničenosti dostupnosti brojčanih podataka u IFS-ovoj bazi podataka, kao referentna kamatna stopa za Hrvatsku uzeta je iz baze ECB-a, dok su za ostale zemlje kamatne stope uzete iz OECD-ove baze, u kojoj podataka za Hrvatsku nema. Sve varijable, osim indeksa potrošačkih cijena, su bile u obliku stvarnih

vrijednosti ili postotaka, te su zbog potreba analize kako je već spomenuto indeksirane na siječanj 2010.

U samom istraživanju glavna regresand varijabla je indeksirana vrijednost burzovnih indeksa, dok je glavna regresorska varijabla cijena nafte, ostale regresorske varijable su indeksirane vrijednosti ponude nafte (šok ponude), industrijske proizvodnje, potrošačkih cijena, kamatne stope, te tečaja.

3.2. METODOLOGIJA ISTRAŽIVANJA

Pri pristupu razvijanja metodologije istraživanja problema utjecaja nafte i ostalih varijabli na burzovne indekse primjenjen je pozitivistički pristup. Formulirane hipoteze testirane su na temelju prikazanih varijabli kroz razvijeni model. Kao glavni zaključci istraživanja uzimaju se rezultati dobiveni modelom.

Samo testiranje promatranih varijabli i modela sastoji se iz više različitih koraka.

Prvi korak obuhvaća promatranje svih varijabli za sve zemlje, te utvrđivanje njihove stacionarnosti provođenjem testa jediničnog korjena koristeći Phillips-Perronov test. Kako bi se utvrdila vrijednost testa na levelu, prvoj i drugoj diferenciji prije je proveden test korelograma za svaku varijablu na levelu i obje diferencije, kako bi se donijela odluka o postojanju ili odsutnosti postojanja trenda. Uočeno je postojanje trenda za veliku većinu varijabli na levelima, no diferenciranjem trend se gubi, te su sve varijable stacionarne pri I(1). Detaljniji opis postupka utvrđivanja trenda nije opisan u radu zbog ograničenosti opsega rada.

Kao drugi korak u radu primjenjen je test optimalnog broja “lagova” za svaki model. Ovaj korak je iznimno bitan zbog toga što premali broj pomaka može uzrokovati pojavu problema autokorelacije, dok prevelik izbor može uzrokovati prevelik broj parametara koji može dovesti do problema sa interpretiranjem.

Ko treći korak provedeni su Johansenov test kointegracije i test Grangerove kauzalnosti, kako bi se izabralo između VAR ili VECM modela. VAR model čak i u slučaju pojave kointegracije nije pogrešan za uporabu, no zbog bolje interpretacije i točnije procjene parametara u ovom slučaju

koristi se model korekcije pogreške (ECM), odnosno kod više varijabli vektorski model korekcije pogreške (VECM). Četvrti i posljednji korak obuhvaća procjenu VECM modela,. Naravno u ovim koracima koristimo prije dobiveni optimalni broj pomaka, kao i vremenske nizove koji su stacionarni na prvoj diferenciji, I(1). Podatci o impulsnim odgovorima promatrane varijable provedeni su nakon procjene VECM modela. Provedena je i procjena parametara modela, te utvrđena njihova signifikantnost koristeći metodu najmanjih kvadrata.

3.3. REZULTATI ISTRAŽIVANJA

3.3.1. Njemačka

U empirijskoj analizi prvo se prišlo analizi podataka iz Njemačke, a potom je jednaka metodologija primjenjena na ostalim zemljama iz uzorka. Prema dobivenim rezultatima (Tablica 4.), niti jedna od promatranih varijabli ne pokazuje jedinični korjen, te možemo zaključiti kako su sve varijable stacionarne na razini I(1).

Tablica 4: Rezultati Phillips-Perronovog testa, Njemačka

Njemačka - Phillips-Perron test jediničnog korjena D(X)					
Null Hipoteza: D(X) ima jedinični korjen Egzogena: Konstanta					
D(burzovni indeks - DAX)	Adj. t-Stat	Prob.*	D(indeks potrošačkih cijena)	Adj. t-Stat	Prob.*
Phillips-Perron test statistic	-9.64	0.00	Phillips-Perron test statistic	-14.09	0.00
D(devizni tečaj)	Adj. t-Stat	Prob.*	D(indeks industrijske proizv.)	Adj. t-Stat	Prob.*
Phillips-Perron test statistic	-8.45	0.00	Phillips-Perron test statistic	-49.29	0.00
D(kratkor. kamatna stopa)	Adj. t-Stat	Prob.*	D(cijena nafte)	Adj. t-Stat	Prob.*
Phillips-Perron test statistic	-4.66	0.00	Phillips-Perron test statistic	-6.49	0.00
D(količina nafte)	Adj. t-Stat	Prob.*	*MacKinnon (1996) one-sided p-values		
Phillips-Perron test statistic	-11.15	0.00			
Test critical values: 1% level	-3.49				
5% level	-2.89				
10% level	-2.58				

Izvor: Izrada autora.

Rezultati Phillips Perronovog testa vidljivi su u tablici 4. Optimalan broj pomaka iznosi 12 prema LR, FPE i AIC informacijskim kriterijima (Tablica P1.), no zbog VECM modela, koristi se broj pomaka 11, po formuli „p-1“, po kojoj p predstavlja optimalan broj pomaka iz tablice.

Prema rezultatima provedenog Grangerova testa može se zaključiti da vatijabla DAX burzovni indeks uzrokuju kretanja varijabli indeks potrošačkih cijena, kamatna stopa, indeks industrijske proizvodnje i količina nafte, podatci dostupni u tablici P2. Johansenov test kointegracije pokazuje kako postoji postoji pet kointegracijskih vektora. Test kointegracije dostupan je u tablici 5.

Tablica 5: Johansenov test, Njemačka

Unrestricted Cointegration Rank Test (Trace)				
Hypothesized No. of CE(s)	**Eigenvalue**	**Trace Statistic**	**0.05 Critical value**	**Prob.****
None *	0.85	503.04	125.62	0.00
At most 1 *	0.67	301.84	95.75	0.00
At most 2 *	0.59	180.95	69.82	0.00
At most 3 *	0.34	85.34	47.86	0.00
At most 4 *	0.25	40.95	29.80	0.00
At most 5	0.09	10.56	15.50	0.24
At most 6	0.00	0.14	3.84	0.71
Trace test indicates 5 cointegrating eqn(s) at the 0.05 level * denotes rejection of the hypothesis at the 0.05 level **MacKinnon-Haug-Michelis (1999) p-values				

Izvor: Izrada autora.

Temeljem testa kointegracije procjenjena je jednadžba oblika:

$$D(INDX) = C(1)*(INDX(-1) - 0.02*PO(-1) - 6.73*QO(-1) + 562.07) + C(2)*(CPI(-1) - 0.03*PO(-1) - 1.21*QO(-1) + 24.46) + C(3)*(EXR(-1) + 0.11*PO(-1) - 2.99*QO(-1) + 187.89) + C(4)*(IP(-1) - 0.14*PO(-1) - 1.42*QO(-1) + 39.30) + C(5)*(IR(-1) + 2.28*PO(-1) + 62.06*QO(-1) - 6849.20) + C(6) * D(INDX(-1) + ... + C(16) * D(INDX(-11) + C(17) * D(CPI(-1) + ... + C(27) * D(CPI(-11) + C(28) * D(EXR(-1) + ... + C(38) * D(EXR(-11) + C(39) * D(IP(-1) + ... + C(49) * D(IP(-11) + C(50) * D(IR(-1) + ... + C(60) * D(IR(-11) + C(61) * D(PO(-1) + ... + C(71) * D(QO(-11) + C(72) * D(PO(-1) + ... + C(82) * D(QO(-11) + C(83)., \quad (1.)$$

te na temelju procijenjenih koefcijenata (iz Tablice 6.) koji su statistički značajni glasi:

$$D(INDX) = -0.97*(INDX(-1) - 0.02*PO(-1) - 6.73*QO(-1) + 562.07) - 2.94*(EXR(-1) + 0.11*PO(-1) - 2.99*QO(-1) + 187.89) + 0.69*D(INDX(-1)) + 0.68*D(INDX(-3)) + 0.72*D(INDX(-4)) + 0.50*D(INDX(-5) + 0.54*D(INDX(-6)) + 0.43*D(INDX(-8)) + 0.58*D(INDX(-9)) + 16.84*D(CPI(-3)) + 16.26*D(CPI(-4)) + 17.92*D(CPI(-7)) + 1.68*D(EXR(-2)) - 0.17*D(IR(-10)) + 0.50*D(PO(-1)) - 0.41*D(PO(-4)) - 0.38*D(PO(-6)) - 0.53*D(PO(-8)) - 6.41*D(QO(-2)), \quad (2.)$$

gdje se oznaka INDX odnosi na DAX indeks, CPI na indeks potrošačkih cijena, EXR na tečaj eura, IP na industrijsku proizvodnju, IR na kratkoročnu kamatnu stopu, PO na cijenu, a QO količinu nafte. Procjenjeni koeficijenti jednadžbe nalaze se u tablici 6., te su statistički značajni koeficijenti podebljani. Granica statističke značajnosti je 10%, odnosno 0,10.

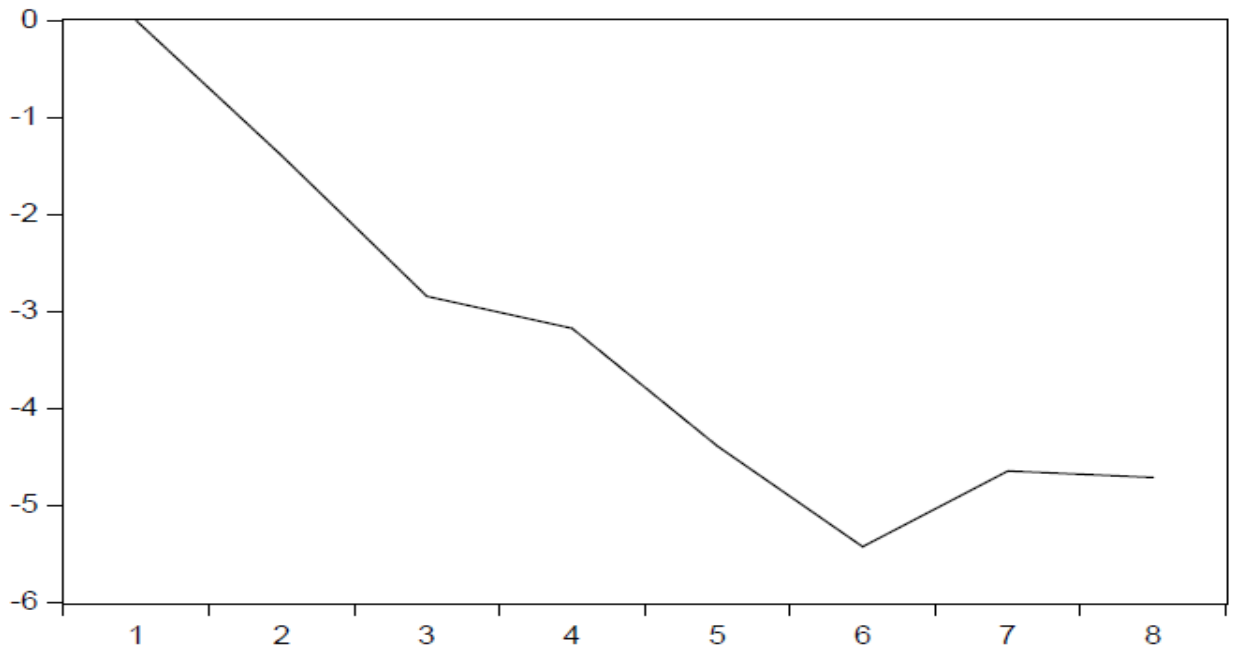
Prema dobivenim rezultatima možemo vidjeti (Tablica 6.), na temelju ekonometrijske analize za kratki rok, kako na kretanje DAX burzovnog indeksa utječu varijable indeks potrošačkih cijena, devizni tečaj, kamatne stope, cijena nafte i količina proizvedene nafte. Glavna istraživačka varijabla ovog istraživanja je da (cijena nafte) utječe na kretanje DAX indeksa. U dugom roku može se vidjeti kako varijable, u kointegrirajućem vektoru, devizni tečaj, cijena i količina nafte, te konstantni član imaju utjecaj na kretanje DAX-a. Utjecaj cijene nafte na DAX u dugom roku, prema ovom istraživanju postoji. Na grafikonu 10. prikazan je impulsni odgovor varijable DAX indeks na povećanje cijene nafte, te se može vidjeti da je kretanje DAX-a inverzno kretanju cijene nafte.

Tablica 6: VECM procjena metodom najmanjih kvadrata, Njemačka

	Koeficijent	St. Greška	t-Statistic	Prob.		Koeficijent	St. Greška	t-Statistic	Prob.
C(1)	**-0.97**	**0.29**	**-3.36**	**0.00**	**C(43)**	-0.79	1.00	-0.79	0.44
C(2)	4.04	2.62	1.54	0.14	**C(44)**	-0.44	0.90	-0.49	0.63
C(3)	**-2.94**	**0.93**	**-3.16**	**0.00**	**C(45)**	-0.39	0.72	-0.53	0.60
C(4)	1.83	1.15	1.59	0.12	**C(46)**	-0.19	0.60	-0.32	0.75
C(5)	-0.02	0.03	-0.71	0.48	**C(47)**	-0.30	0.47	-0.65	0.52
C(6)	**0.69**	**0.26**	**2.69**	**0.01**	**C(48)**	0.10	0.35	0.28	0.78
C(7)	0.30	0.28	1.08	0.29	**C(49)**	0.15	0.21	0.74	0.47
C(8)	**0.68**	**0.30**	**2.27**	**0.03**	**C(50)**	0.11	0.08	1.48	0.15
C(9)	**0.72**	**0.30**	**2.36**	**0.03**	**C(51)**	0.05	0.09	0.52	0.60
C(10)	**0.50**	**0.30**	**1.70**	**0.10**	**C(52)**	0.13	0.10	1.30	0.20
C(11)	**0.54**	**0.30**	**1.79**	**0.09**	**C(53)**	0.06	0.10	0.59	0.56
C(12)	0.18	0.23	0.79	0.44	**C(54)**	-0.02	0.09	-0.24	0.81
C(13)	**0.43**	**0.22**	**1.98**	**0.06**	**C(55)**	0.04	0.08	0.52	0.61
C(14)	**0.58**	**0.23**	**2.50**	**0.02**	**C(56)**	0.00	0.07	0.00	1.00
C(15)	0.40	0.24	1.68	0.11	**C(57)**	-0.05	0.08	-0.60	0.55
C(16)	0.30	0.22	1.40	0.17	**C(58)**	0.08	0.09	0.88	0.39
C(17)	-6.21	6.68	-0.93	0.36	**C(59)**	**-0.17**	**0.08**	**-2.10**	**0.05**
C(18)	5.64	9.31	0.61	0.55	**C(60)**	0.08	0.08	0.97	0.34
C(19)	**16.84**	**9.34**	**1.80**	**0.08**	**C(61)**	**0.50**	**0.29**	**1.73**	**0.10**
C(20)	**16.26**	**8.54**	**1.90**	**0.07**	**C(62)**	0.22	0.27	0.80	0.43
C(21)	9.55	9.50	1.01	0.32	**C(63)**	0.01	0.26	0.03	0.98
C(22)	10.45	9.22	1.13	0.27	**C(64)**	**-0.41**	**0.23**	**-1.73**	**0.10**
C(23)	**17.92**	**9.61**	**1.87**	**0.07**	**C(65)**	-0.10	0.23	-0.45	0.66
C(24)	15.17	9.53	1.59	0.12	**C(66)**	**-0.38**	**0.21**	**-1.76**	**0.09**
C(25)	9.56	9.38	1.02	0.32	**C(67)**	-0.35	0.24	-1.50	0.15
C(26)	-0.60	7.91	-0.08	0.94	**C(68)**	**-0.53**	**0.25**	**-2.16**	**0.04**
C(27)	-3.23	5.92	-0.55	0.59	**C(69)**	-0.43	0.26	-1.64	0.11
C(28)	1.31	0.82	1.59	0.13	**C(70)**	-0.16	0.24	-0.65	0.52
C(29)	**1.68**	**0.72**	**2.32**	**0.03**	**C(71)**	0.08	0.20	0.37	0.71
C(30)	0.69	0.65	1.05	0.30	**C(72)**	-3.54	3.55	-1.00	0.33
C(31)	0.96	0.67	1.43	0.17	**C(73)**	**-6.41**	**3.73**	**-1.72**	**0.10**
C(32)	0.55	0.53	1.04	0.31	**C(74)**	-2.70	3.29	-0.82	0.42
C(33)	-0.38	0.58	-0.65	0.52	**C(75)**	-0.26	3.38	-0.08	0.94
C(34)	0.31	0.53	0.58	0.56	**C(76)**	2.01	3.67	0.55	0.59
C(35)	-0.24	0.49	-0.48	0.63	**C(77)**	0.97	3.15	0.31	0.76
C(36)	-0.12	0.54	-0.23	0.82	**C(78)**	0.37	2.85	0.13	0.90
C(37)	0.13	0.43	0.31	0.76	**C(79)**	-1.71	2.75	-0.62	0.54
C(38)	-0.07	0.47	-0.14	0.89	**C(80)**	-0.22	2.61	-0.08	0.93
C(39)	-1.32	1.18	-1.12	0.27	**C(81)**	-1.55	2.77	-0.56	0.58
C(40)	-1.36	1.17	-1.16	0.26	**C(82)**	-3.16	2.35	-1.35	0.19
C(41)	-0.93	1.16	-0.80	0.43	**C(83)**	-9.32	7.53	-1.24	0.23
C(42)	-0.94	1.10	-0.85	0.40					

R-squared	0.85	Mean dependent var	0.56
Adjusted R-squared	0.39	S.D. dependent var	7.51
S.E. of regression	6.09	Akaike info criterion	6.52
Sum squared resid	930.20	Schwarz criterion	8.59
Log likelihood	-269.52	Hannan-Quinn criter.	7.36
F-statistic	1.82	Durbin-Watson stat	1.92

Izvor: Izrada autora.



Grafikon 10: Impulsni odgovor DAX indeksa na povečanje cijene nafte

Izvor: Izrada autora.

Temeljem provedene analize može se prihvatiti prva hipoteza za Njemačku o uočenom utjecaju cijena nafte na kretanje DAX burzovnog indeksa u kratkom i dugom roku (druga hipoteza će biti analizirana u dijelu 3.4. Rasprava istraživanja). Zanimljivo je također primjetiti kako u Njemačkoj nafta ima značajan utjecaj na indeks kroz šok ponude (količina nafte).

3.3.2. Francuska

Sljedeća zemlja u empirijskoj analizi je Francuska. Prema dobivenim rezultatima Phillips-Perronovog testa, niti jedna od promatranih varijabli ne pokazuje jedinični korjen, te možemo zaključiti kako su sve varijable stacionarne na razini I(1), tablica 7. Podatci o jediničnom korjenu varijabli cijena i količina nafte dostupni su u tablici 7., te njihove vrijednosti su iste za sve zemlje. Optimalan broj pomaka iznosi 12 prema LR, FPE, AIC i HQ informacijskim kriterijima (Tablica P1.), te se koristi broj pomaka 11, kao i u slučaju Njemačke („p-1“).

Tablica 7: Rezultati Phillips-Perronovog testa, Francuska

Francuska - Phillips-Perron test jediničnog korjena D(X)					
Null Hipoteza: D(X) ima jedinični korjen Egzogena: Konstanta					
D(burzovni indeks - CAC40)	Adj. t-Stat	Prob.*	D(indeks potrošačkih cijena)	Adj. t-Stat	Prob.*
Phillips-Perron test statistic	-9.46	0.00	Phillips-Perron test statistic	-12.41	0.00
D(devizni tečaj)	Adj. t-Stat	Prob.*	D(indeks industrijske proizv.)	Adj. t-Stat	Prob.*
Phillips-Perron test statistic	-8.46	0.00	Phillips-Perron test statistic	-26.84	0.00
D(kratkor. kamatna stopa)	Adj. t-Stat	Prob.*	*MacKinnon (1996) one-sided p-values		
Phillips-Perron test statistic	-4.66	0.00			
Test critical values: 1% level	-3.49				
5% level	-2.89				
10% level	-2.58				

Izvor: Izrada autora.

Prema rezultatima provedenog Grangerova testa može se zaključiti da na varijablu CAC40 burzovni indeks utjecaj imaju kretanja varijabli indeks potrošačkih cijena, indeks industrijske proizvodnje, kamatna stopa i količina nafte, podatci dostupni u tablici P2. Johansenov test kointegracije pokazuje kako postoji postoji šest kointegracijskih vektora. Test kointegracije dostupan je u tablici 8.

Tablica 8: Johansenov test, Francuska

Unrestricted Cointegration Rank Test (Trace)				
Hypothesized No. of CE(s)	**Eigenvalue**	**Trace Statistic**	**0.05 Critical value**	**Prob.** ***
None *	0.86	461.47	125.62	0.00
At most 1 *	0.58	253.07	95.75	0.00
At most 2 *	0.52	159.45	69.82	0.00
At most 3 *	0.26	80.18	47.86	0.00
At most 4 *	0.21	47.26	29.80	0.00
At most 5 *	0.17	22.42	15.50	0.00
At most 6	0.02	2.06	3.84	0.15
Trace test indicates 6 cointegrating eqn(s) at the 0.05 level * denotes rejection of the hypothesis at the 0.05 level **MacKinnon-Haug-Michelis (1999) p-values				

Izvor: Izrada autora.

Temeljem rezultata Johansenovog testa kointegracije procjenjena je jednadžba oblika:

$$D(INDX) = C(1)*(INDX(-1) - 2.71*QO(-1) + 174.58) + C(2)*(CPI(-1) - 0.72*QO(-1) -28.84) + C(3)*(EXR(-1) - 2.72*QO(-1) + 172.68) + C(4)*(IP(-1) - 0.50*QO(-1) - 53.43) + C(5)*(IR(-1) + 13.71*QO(-1) - 1573.67) + C(6)*(PO(-1) + 2.31*QO(-1) - 351.66) + C(7)*D(INDX(-1) + ... + C(17)*D(INDX(-11) + C(18)*D(CPI(-1) + ... + C(28)*D(CPI(-11) + C(29) * D(EXR(-1) + ... + C(39) * D(EXR(-11) + C(40) * D(IP(-1) + ... + C(50) * D(IP(-11) + C(51)*D(IR(-1) + ... + C(61) * D(IR(-11) + C(62)*D(PO(-1) + ... + C(72)*D(QO(-11) + C(73)*D(PO(-1) + ... + C(83) * D(QO(-11) + C(84)., \quad (3.)$$

te na temelju procijenjenih koefcijenata (iz Tablice 9.) koji su statistički značajni glasi:

$$D(INDX) = -0.57*(INDX(-1) - 2.71*QO(-1) + 174.58) – 1.97*(EXR(-1) - 2.72*QO(-1) + 172.68) + 4.96*(IP(-1) - 0.50*QO(-1) - 53.43) – 0.12*(IR(-1) + 13.71*QO(-1) - 1573.67) + 0.62*D(INDX(-4)) + 0.51*D(INDX(-5)) + 0.60*D(INDX(-6)) + 0.60*D(INDX(-7)) – 13.74*D(CPI(-3)) – 4.64*D(IP(-2)) – 4.67*D(IP(-3)) – 3.98*D(IP(-4)) – 3.60*D(IP(-5)) – 3.33*D(IP(-6)) – 2.96*D(IP(-7)) – 2.62*D(IP(-8)) – 1.78*D(IP(-9)) + 0.17* D(IR(-1)) + 0.14*D(IR(-3)) – 3.26*D(QO(-11)), \quad (4.)$$

gdje se oznaka INDX odnosi na CAC40 indeks, CPI na indeks potrošačkih cijena, EXR na tečaj eura, IP na industrijsku proizvodnju, IR na kratkoročnu kamatnu stopu, PO na cijenu, a QO količinu nafte. Procjenjeni koeficijenti jednadžbe nalaze se u tablici 9., te su statistički značajni koeficijenti podebljani. Granica statističke značajnosti je 10%, odnosno 0,10.

Prema dobivenim rezultatima (Tablica 9.) možemo vidjeti, na temelju ekonometrijske analize za kratki rok, kako na kretanje CAC40 burzovnog indeksa utječu varijable indeks potrošačkih cijena, indeks industrijske proizvodnje, kratkoročne kamatne stope i količina proizvedene nafte. Glavna istraživačka varijabla u ovom radu, cijena nafte, nema utjecaj na kretanje promatranog indeksa u kratkom roku. U dugom roku može se vidjeti kako varijable količina proizvedene nafte, tečaj eura prema dolaru i kratkoročne kamatne stope utječu na kretanje indeksa. Utjecaj cijene nafte na indeks u dugom roku ne postoji.

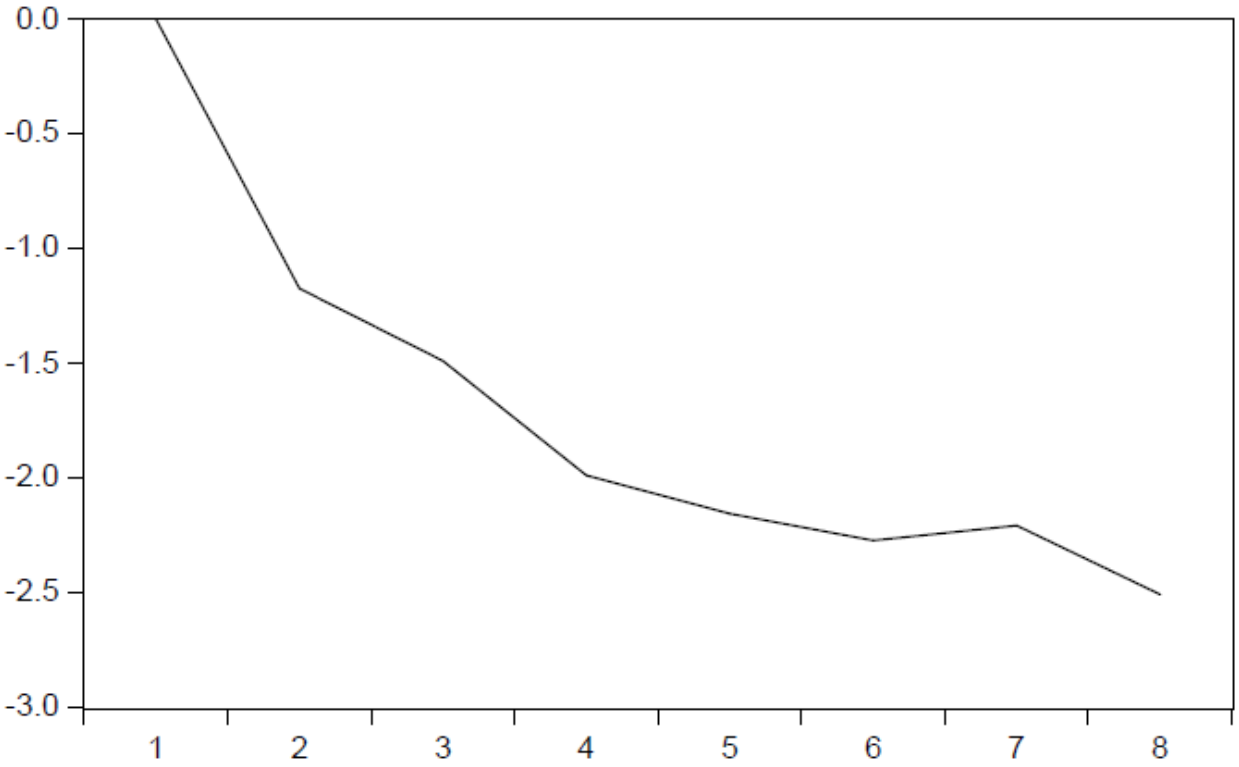
Tablica 9: VECM procijenjen metodom najmanjih kvadrata, Francuska

	Koeficijent	St. Greška	t-Statistic	Prob.		Koeficijent	St. Greška	t-Statistic	Prob.
C(1)	**-0.57**	**0.28**	**-2.05**	**0.05**	**C(43)**	**-3.98**	**1.37**	**-2.90**	**0.01**
C(2)	-1.65	3.01	-0.55	0.59	**C(44)**	**-3.60**	**1.22**	**-2.96**	**0.01**
C(3)	**-1.97**	**0.73**	**-2.69**	**0.01**	**C(45)**	**-3.33**	**1.10**	**-3.04**	**0.01**
C(4)	**4.96**	**1.79**	**2.78**	**0.01**	**C(46)**	**-2.96**	**0.92**	**-3.20**	**0.00**
C(5)	**-0.12**	**0.04**	**-2.90**	**0.01**	**C(47)**	**-2.62**	**0.84**	**-3.12**	**0.00**
C(6)	-0.30	0.20	-1.53	0.14	**C(48)**	**-1.78**	**0.74**	**-2.40**	**0.02**
C(7)	0.18	0.32	0.55	0.59	**C(49)**	-0.87	0.54	-1.60	0.12
C(8)	0.07	0.32	0.21	0.83	**C(50)**	-0.06	0.32	-0.18	0.86
C(9)	0.40	0.29	1.40	0.17	**C(51)**	**0.17**	**0.07**	**2.38**	**0.03**
C(10)	**0.62**	**0.25**	**2.44**	**0.02**	**C(52)**	0.09	0.08	1.09	0.28
C(11)	**0.51**	**0.26**	**1.97**	**0.06**	**C(53)**	**0.14**	**0.07**	**1.88**	**0.07**
C(12)	**0.60**	**0.27**	**2.22**	**0.04**	**C(54)**	0.00	0.07	-0.03	0.98
C(13)	**0.60**	**0.24**	**2.49**	**0.02**	**C(55)**	0.00	0.07	-0.06	0.95
C(14)	0.13	0.25	0.50	0.62	**C(56)**	0.01	0.06	0.21	0.84
C(15)	0.33	0.24	1.38	0.18	**C(57)**	0.00	0.06	0.02	0.98
C(16)	0.14	0.22	0.64	0.53	**C(58)**	0.01	0.06	0.16	0.87
C(17)	0.18	0.22	0.84	0.41	**C(59)**	0.06	0.06	0.94	0.36
C(18)	4.42	5.65	0.78	0.44	**C(60)**	-0.08	0.06	-1.24	0.23
C(19)	7.66	6.56	1.17	0.25	**C(61)**	0.06	0.05	1.21	0.24
C(20)	**13.74**	**7.41**	**1.85**	**0.08**	**C(62)**	0.09	0.22	0.40	0.69
C(21)	4.78	8.09	0.59	0.56	**C(63)**	0.05	0.21	0.24	0.81
C(22)	-5.60	7.39	-0.76	0.46	**C(64)**	-0.10	0.23	-0.44	0.66
C(23)	0.07	8.10	0.01	0.99	**C(65)**	-0.33	0.23	-1.45	0.16
C(24)	9.69	7.17	1.35	0.19	**C(66)**	-0.04	0.21	-0.18	0.86
C(25)	1.91	6.62	0.29	0.78	**C(67)**	-0.12	0.20	-0.59	0.56
C(26)	-1.68	6.57	-0.26	0.80	**C(68)**	-0.16	0.20	-0.81	0.43
C(27)	-6.95	6.00	-1.16	0.26	**C(69)**	-0.15	0.18	-0.86	0.40
C(28)	0.52	5.12	0.10	0.92	**C(70)**	-0.03	0.18	-0.17	0.86
C(29)	1.68	0.72	2.32	0.03	**C(71)**	-0.04	0.16	-0.23	0.82
C(30)	1.18	0.67	1.76	0.09	**C(72)**	0.15	0.15	1.01	0.32
C(31)	0.78	0.70	1.12	0.27	**C(73)**	-1.92	2.13	-0.90	0.38
C(32)	0.62	0.64	0.97	0.34	**C(74)**	-1.86	2.06	-0.90	0.37
C(33)	0.66	0.57	1.15	0.26	**C(75)**	-1.87	2.07	-0.91	0.37
C(34)	0.53	0.53	1.00	0.33	**C(76)**	1.16	1.83	0.63	0.53
C(35)	0.56	0.50	1.12	0.27	**C(77)**	2.30	1.91	1.21	0.24
C(36)	0.10	0.45	0.21	0.83	**C(78)**	2.10	1.96	1.07	0.29
C(37)	0.33	0.43	0.77	0.45	**C(79)**	2.98	1.87	1.60	0.12
C(38)	0.11	0.42	0.25	0.80	**C(80)**	0.58	2.04	0.29	0.78
C(39)	0.19	0.34	0.55	0.59	**C(81)**	0.10	1.64	0.06	0.95
C(40)	0.44	0.33	1.34	0.19	**C(82)**	-0.85	1.65	0.01	0.61
C(41)	**-4.64**	**1.73**	**-2.68**	**0.01**	**C(83)**	**-3.26**	**1.73**	**-1.88**	**0.07**
C(42)	**-4.67**	**1.58**	**-2.95**	**0.01**	**C(84)**	-4.25	4.46	-0.95	0.35

R-squared	0.85	Mean dependent var	-0.19
Adjusted R-squared	0.33	S.D. dependent var	5.71
S.E. of regression	4.66	Akaike info criterion	5.97
Sum squared resid	521.76	Schwarz criterion	8.05
Log likelihood	-238.30	Hannan-Quinn criter.	6.81
F-statistic	1.64	Durbin-Watson stat	1.81

Izvor: Izrada autora.

Na grafikonu 11. prikazan je impulsni odgovor varijable CAC40 indeks na povećanje cijene nafte, te se može vidjeti da je kretanje promatranih varijabli obratno, odnosno sa porastom cijene nafte vrijednost indeksa se smanjuje.



Grafikon 11: Impulsni odgovor CAC40 indeksa na povećanje cijene nafte

Izvor: Izrada autora.

U slučaju Francuske i CAC40 indeksa odbacujemo prvu hipotezu kako postoji utjecaj cijena nafte na kretanje indeksa, u kratkom i dugom roku.

3.3.3. Austrija

U nastavku rada je analizirana Austrija. Test jediničnog korjena pokazuje da su sve promatrane varijable pri I(1) stacionarne, prikazano u tablici 10. Optimalan broj pomaka iznosi 12 prema LR, FPE, AIC i HQ informacijskim kriterijima (Tablica P1.), te se u analizi kao i u prethodnim slučajevima uzima 11 („p-1“).

Tablica 10: Rezultati Phillips-Perronovog testa, Austrija

Austrija - Phillips-Perron test jediničnog korjena D(X)					
Null Hipoteza: D(X) ima jedinični korjen Egzogena: Konstanta					
D(burzovni indeks - ATX)	Adj. t-Stat	Prob.*	D(indeks potrošačkih cijena)	Adj. t-Stat	Prob.*
Phillips-Perron test statistic	-8.79	0.00	Phillips-Perron test statistic	-13.11	0.00
D(devizni tečaj)	Adj. t-Stat	Prob.*	D(indeks industrijske proizv.)	Adj. t-Stat	Prob.*
Phillips-Perron test statistic	-8.46	0.00	Phillips-Perron test statistic	-45.53	0.00
D(kratkor. kamatna stopa)	Adj. t-Stat	Prob.*	*MacKinnon (1996) one-sided p-values		
Phillips-Perron test statistic	-4.66	0.00			
Test critical values: 1% level	-3.49				
5% level	-2.89				
10% level	-2.58				

Izvor: Izrada autora.

Prema rezultatima provedenog Grangerova testa može se zaključiti da na varijablu ATX burzovni indeks nemaju direktnog utjecaja promatrane varijable, no pitanje će se dodatno istražiti VEC modelom (Tablica P2.). Test kointegracije dostupan je u tablici 11., te vidimo kako postoji šest kointegracijskih jednadžbi.

Tablica 11: Johansenov test kointegracije, Austrija

Unrestricted Cointegration Rank Test (Trace)				
Hypothesized No. of CE(s)	**Eigenvalue**	**Trace Statistic**	**0.05 Critical value**	**Prob.****
None *	0.79	446.79	125.62	0.00
At most 1 *	0.65	279.75	95.75	0.00
At most 2 *	0.49	165.84	69.82	0.00
At most 3 *	0.32	93.45	47.86	0.00
At most 4 *	0.26	51.29	29.80	0.00
At most 5 *	0.14	19.39	15.50	0.01
At most 6	0.02	2.62	3.84	0.11
Trace test indicates 6 cointegrating eqn(s) at the 0.05 level * denotes rejection of the hypothesis at the 0.05 level **MacKinnon-Haug-Michelis (1999) p-values				

Izvor: Izrada autora.

Temeljem rezultata Johansenova testa kointegracije procjenjena je jednadžba oblika:

D(INDX) = C(1)*(INDX(-1) – 3.47*QO(-1) + 240.88) + C(2)*(CPI(-1) -1.19*QO(-1) -16.90) + C(3)*(EXR(-1) - 2.48*QO(-1) + 146.87) + C(4)*(IP(-1) - 2.63*QO(-1) - 145.46) + C(5)*(IR(-1) - 11.91*QO(-1) - 1085.51) + C(6)*(PO(-1) + 1.32*QO(-1) - 248.84) + C(7)*D(INDX(-1) + ... + C(17)*D(INDX(-11) + C(18)*D(CPI(-1) + ... + C(28)*D(CPI(-11) + C(29) * D(EXR(-1) + ... + C(39) * D(EXR(-11) + C(40) * D(IP(-1) + ... + C(50) * D(IP(-11) + C(51)*D(IR(-1) + ... + C(61) * D(IR(-11) + C(62)*D(PO(-1) + ... + C(72)*D(QO(-11) + C(73)*D(PO(-1) + ... + C(83) * D(QO(-11) + C(84)., (5.)

te na temelju procijenjenih koefcijenata koji su statistički značajni glasi (Tablica 12.):

D(INDX) = -13.21*(CPI(-1) -1.19*QO(-1) -16.90) – 2.85*(EXR(-1) - 2.48*QO(-1) + 146.87) + 9.64*(IP(-1) - 2.63*QO(-1) - 145.46) – 0.23*(IR(-1) - 11.91*QO(-1) - 1085.51) – 0.61*(PO(-1) + 1.32*QO(-1) - 248.84) - 0.57*D(INDX(-2)) + 0.38*D(INDX(-9)) + 0.43*D(INDX(-10)) + 10.89* D(CPI(-4)) + 11.75* D(CPI(-6)) + 2.12*D(EXR(-1)) + 2.37*D(EXR(-2)) + 2.21*D(EXR(-3)) + 2.29*D(EXR(-4)) – 8.86*D(IP(-1)) – 7.81* D(IP(-2)) – 6.99*D(IP(-3)) – 5.83*D(IP(-4)) – 5.11* D(IP(-5)) – 4.18*D(IP(-6)) – 3.00*D(IP(-7)) – 2.24*D(IP(-8)) + 1.53*D(IP(-9)) - 1.16*D(IP(-10)) – 0.76*D(IP(-11)) + 0.19*D(IR(-1)) + 0.58*D(PO(-1)) - 0.52*D(PO(-2)) + 0.55* D(PO(-3)) - 0.37*D(PO(-7)) - 0.32*D(PO(-8)) + 7.71 *D(QO(-5)) + 8.48 *D(QO(-6)) + 6.63*D(QO(-7)), (6.)

gdje se oznaka INDX odnosi na ATX indeks, CPI na indeks potrošačkih cijena, EXR na tečaj eura, IP na industrijsku proizvodnju, IR na kratkoročnu kamatnu stopu, PO na cijenu, a QO količinu nafte. Procjenjeni koeficijenti jednadžbe nalaze se u tablici 12., te su statistički značajni koeficijenti podebljani. Granica statističke značajnosti je 10%, odnosno 0,10.

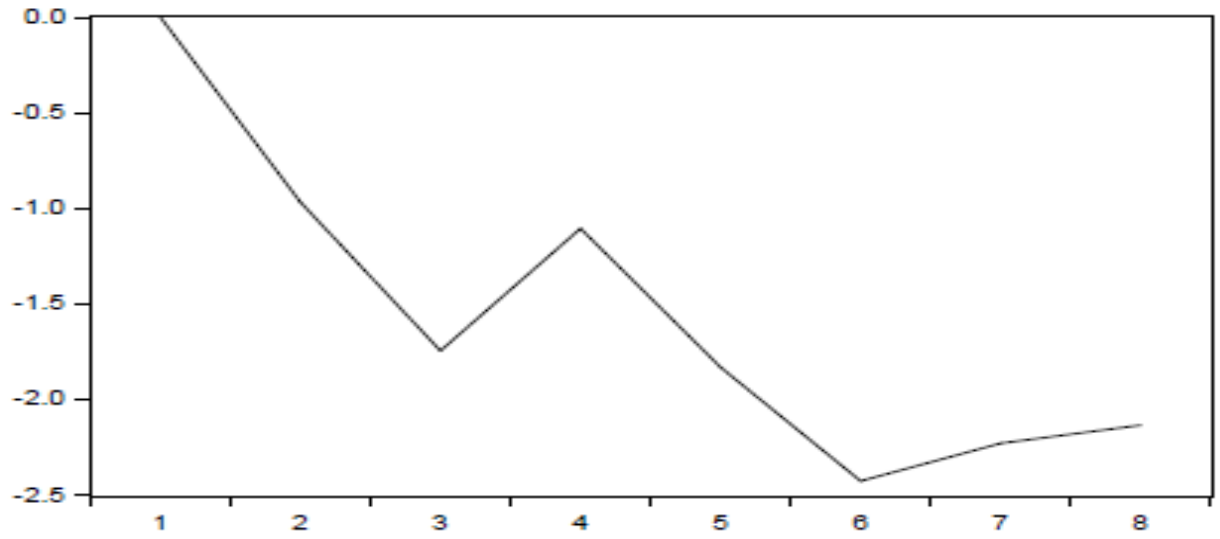
U slučaju kretanja ATX indeksa, može se vidjeti iz provedene analize (Tablica 12.) kako u dugom roku utjecaj imaju indeks potrošačkih cijena, tečaj eura prema dolaru, kratkoročne kamatne stope, cijena i količina nafte, te konstanta. U kratkom roku vide se utjecaji varijabli indeks potrošačkih cijena, devizni tečaj, indeks industrijske proizvodnje, kratkoročne kamatne stope, količina i cijena nafte. Na grafikonu 12. prikazan je impulsni odgovor varijable ATX indeks na povećanje cijene nafte, te se uočava isti smjer kretanja kao i u slučaju CAC40 i DAX indeksa, odnosno sa porastom cijene nafte vrijednost indeksa se smanjuje.

Tablica 12: VECM procijenjen metodom najmanjih kvadrata, Austrija

	Koeficijent	St. Greška	t-Statistic	Prob.		Koeficijent	St. Greška	t-Statistic	Prob.
C(1)	-0.07	0.18	-0.37	0.72	**C(43)**	**-5.83**	**1.79**	**-3.26**	**0.00**
C(2)	**-13.21**	**4.22**	**-3.13**	**0.00**	**C(44)**	**-5.11**	**1.58**	**-3.24**	**0.00**
C(3)	**-2.85**	**1.02**	**-2.79**	**0.01**	**C(45)**	**-4.18**	**1.38**	**-3.03**	**0.01**
C(4)	**9.64**	**2.58**	**3.74**	**0.00**	**C(46)**	**-3.00**	**1.17**	**-2.57**	**0.02**
C(5)	**-0.23**	**0.07**	**-3.55**	**0.00**	**C(47)**	**-2.24**	**0.89**	**-2.53**	**0.02**
C(6)	**-0.61**	**0.30**	**-2.08**	**0.05**	**C(48)**	**-1.53**	**0.64**	**-2.40**	**0.02**
C(7)	-0.22	0.24	-0.89	0.38	**C(49)**	**-1.16**	**0.42**	**-2.72**	**0.01**
C(8)	**-0.57**	**0.23**	**-2.52**	**0.02**	**C(50)**	**-0.76**	**0.26**	**-2.91**	**0.01**
C(9)	-0.26	0.26	-1.01	0.32	**C(51)**	**0.19**	**0.09**	**2.15**	**0.04**
C(10)	-0.09	0.26	-0.37	0.71	**C(52)**	0.11	0.09	1.27	0.22
C(11)	-0.24	0.25	-0.95	0.35	**C(53)**	0.07	0.08	0.93	0.36
C(12)	0.05	0.24	0.20	0.84	**C(54)**	-0.03	0.08	-0.45	0.66
C(13)	0.03	0.22	0.13	0.90	**C(55)**	0.11	0.07	1.45	0.16
C(14)	0.31	0.20	1.53	0.14	**C(56)**	-0.07	0.07	-0.96	0.35
C(15)	**0.38**	**0.21**	**1.81**	**0.08**	**C(57)**	-0.06	0.07	-0.77	0.45
C(16)	**0.43**	**0.25**	**1.71**	**0.10**	**C(58)**	-0.05	0.08	-0.62	0.54
C(17)	0.18	0.19	0.93	0.36	**C(59)**	-0.09	0.08	-1.14	0.27
C(18)	-7.04	5.94	-1.19	0.25	**C(60)**	-0.02	0.07	-0.26	0.80
C(19)	1.51	5.31	0.28	0.78	**C(61)**	0.01	0.07	0.13	0.89
C(20)	-3.42	5.87	-0.58	0.57	**C(62)**	**0.58**	**0.23**	**2.55**	**0.02**
C(21)	**10.89**	**5.45**	**2.00**	**0.06**	**C(63)**	**0.52**	**0.25**	**2.11**	**0.05**
C(22)	7.52	5.01	1.50	0.15	**C(64)**	**0.55**	**0.26**	**2.10**	**0.05**
C(23)	**11.75**	**6.43**	**1.83**	**0.08**	**C(65)**	0.23	0.29	0.82	0.42
C(24)	8.48	6.90	1.23	0.23	**C(66)**	0.21	0.22	0.92	0.36
C(25)	7.54	6.35	1.19	0.25	**C(67)**	0.04	0.20	0.18	0.86
C(26)	-2.63	6.94	-0.38	0.71	**C(68)**	**-0.37**	**0.16**	**-2.24**	**0.03**
C(27)	-0.34	7.03	-0.05	0.96	**C(69)**	**-0.32**	**0.17**	**-1.82**	**0.08**
C(28)	-7.33	7.02	-1.04	0.31	**C(70)**	-0.33	0.21	-1.58	0.13
C(29)	**2.12**	**0.91**	**2.34**	**0.03**	**C(71)**	-0.18	0.18	-1.02	0.32
C(30)	**2.37**	**0.90**	**2.62**	**0.02**	**C(72)**	-0.10	0.16	-0.61	0.55
C(31)	**2.21**	**0.93**	**2.36**	**0.03**	**C(73)**	4.32	3.26	1.33	0.20
C(32)	**2.29**	**0.88**	**2.61**	**0.02**	**C(74)**	5.45	3.32	1.64	0.11
C(33)	1.15	0.73	1.57	0.13	**C(75)**	3.71	3.47	1.07	0.30
C(34)	0.79	0.64	1.23	0.23	**C(76)**	5.53	3.57	1.55	0.13
C(35)	0.20	0.53	0.38	0.71	**C(77)**	**7.71**	**3.70**	**2.09**	**0.05**
C(36)	-0.06	0.57	-0.11	0.91	**C(78)**	**8.48**	**3.48**	**2.44**	**0.02**
C(37)	0.28	0.53	0.54	0.60	**C(79)**	**6.63**	**3.31**	**2.00**	**0.06**
C(38)	-0.08	0.39	-0.21	0.83	**C(80)**	4.88	2.91	1.68	0.11
C(39)	0.58	0.34	1.68	0.11	**C(81)**	3.07	2.55	1.20	0.24
C(40)	**-8.86**	**2.41**	**-3.68**	**0.00**	**C(82)**	3.95	2.64	1.49	0.15
C(41)	**-7.81**	**2.22**	**-3.51**	**0.00**	**C(83)**	1.39	2.25	0.61	0.54
C(42)	**-6.99**	**2.03**	**-3.44**	**0.00**	**C(84)**	-5.39	8.21	-0.66	0.52

R-squared	0.90	Mean dependent var	-0.70
Adjusted R-squared	0.57	S.D. dependent var	7.68
S.E. of regression	5.02	Akaike info criterion	6.12
Sum squared resid	605.11	Schwarz criterion	8.20
Log likelihood	-246.30	Hannan-Quinn criter.	6.96
F-statistic	2.72	Durbin-Watson stat	1.95

Izvor: Izrada autora.



Grafikon 12: Impulsni odgovor ATX indeksa na povećanje cijene nafte

Izvor: Izrada autora.

U slučaju Austrijskog ATX indeksa u dugom roku, cijena nafte, ima utjecaja na kretanje indeksa. U kratkom roku možemo prihvatiti kako utjecaj promjene cijene nafte na indeks postoji. Za oba roka prihvaća se hipoteza da cijena nafte ima utjecaja na kretanje burzovnog indeksa

3.3.4. Slovenija

Prema dobivenim rezultatima za Sloveniju, niti jedna od promatranih varijabli ne pokazuje jedinični korjen, te možemo zaključiti kako su sve varijable stacionarne na razini I(1), prikazano u tablici 13. Optimalan broj pomaka iznosi 12 prema LR, FPE, AIC i HQ informacijskim kriterijima (Tablica P1.), odnosno u analizi se uzima broj pomaka 11, po uvjetu „p-1“.

Tablica 13: Rezultati Phillips-Perronovog testa, Slovenija

Slovenija - Phillips-Perron test jediničnog korjena D(X)					
Null Hipoteza: D(X) ima jedinični korjen Egzogena: Konstanta					
D(burzovni indeks - SBITOP)	Adj. t-Stat	Prob.*	D(indeks potrošačkih cijena)	Adj. t-Stat	Prob.*
Phillips-Perron test statistic	-6.96	0.00	Phillips-Perron test statistic	-7.27	0.00
D(devizni tečaj)	Adj. t-Stat	Prob.*	D(indeks industrijske proizv.)	Adj. t-Stat	Prob.*
Phillips-Perron test statistic	-8.46	0.00	Phillips-Perron test statistic	-25.22	0.00
D(kratkor. kamatna stopa)	Adj. t-Stat	Prob.*	*MacKinnon (1996) one-sided p-values		
Phillips-Perron test statistic	-4.66	0.00			
Test critical values: 1% level	-3.49				
5% level	-2.89				
10% level	-2.58				

Izvor: Izrada autora.

Prema rezultatima provedenog Grangerova testa (Tablica P2.) može se zaključiti da na varijablu SBITOP burzovni indeks utjecaj imaju kretanja varijabli indeks industrijske proizvodnje, kratkoročna kamatna stopa i cijena nafte. Johansenov test kointegracije pokazuje kako postoji postoji šest kointegracijskih vektora. Test kointegracije dostupan je u tablici 14.

Tablica 14: Johansenov test, Slovenija

Unrestricted Cointegration Rank Test (Trace)				
Hypothesized No. of CE(s)	**Eigenvalue**	**Trace Statistic**	**0.05 Critical value**	**Prob.** ***
None *	0.73	451.59	125.62	0.00
At most 1 *	0.64	306.16	95.75	0.00
At most 2 *	0.54	196.69	69.82	0.00
At most 3 *	0.38	112.55	47.86	0.00
At most 4 *	0.31	60.84	29.80	0.00
At most 5 *	0.15	19.82	15.50	0.00
At most 6	0.03	2.85	3.84	0.01
Trace test indicates 6 cointegrating eqn(s) at the 0.05 level * denotes rejection of the hypothesis at the 0.05 level **MacKinnon-Haug-Michelis (1999) p-values				

Izvor: Izrada autora.

Temeljem Johansenova testa procjenjena je jednadžba oblika:

D(INDX) = C(1)*(INDX(-1) – 55.30*QO(-1) + 5655.19) + C(2)*(CPI(-1) - 0.38*QO(-1) - 66.13) + C(3)*(EXR(-1) – 4.13*QO(-1) + 539.27) + C(4)*(IP(-1) - 8.86*QO(-1) - 799.19) + C(5)*(IR(-1) + 152.89*QO(-1) – 15722.84) + C(6)*(PO(-1) + 2.31*QO(-1) - 351.66) + C(7)*D(INDX(-1) + ... + C(17)*D(INDX(-11) + C(18)*D(CPI(-1) + ... + C(28)*D(CPI(-11) + C(29) * D(EXR(-1) + ... + C(39) * D(EXR(-11) + C(40) * D(IP(-1) + ... + C(50) * D(IP(-11) + C(51)*D(IR(-1) + ... + C(61) * D(IR(-11) + C(62)*D(PO(-1) + ... + C(72)*D(QO(-11) + C(73)*D(PO(-1) + ... + C(83) * D(QO(-11) + C(84)., (7.)

te na temelju procijenjenih koefcijenata (Tablica 15.) koji su statistički značajni glasi:

D(INDX) = - 0.54*(INDX(-3) - 5.98*CPI(-1) - 6.27*CPI(-9) + 0.70*EXR(-8) - 0.11*IR(-6) + 0.30*PO(-9) + 0.35*PO(-10), (8.)

gdje se oznaka INDX odnosi na SBITOP indeks, CPI na indeks potrošačkih cijena, EXR na tečaj eura, IP na industrijsku proizvodnju, IR na kratkoročnu kamatnu stopu, PO na cijenu, a QO količinu nafte. Procjenjeni koeficijenti jednadžbe nalaze se u tablici 15., te su statistički značajni koeficijenti podebljani. Granica statističke značajnosti je 10%, odnosno 0,10.

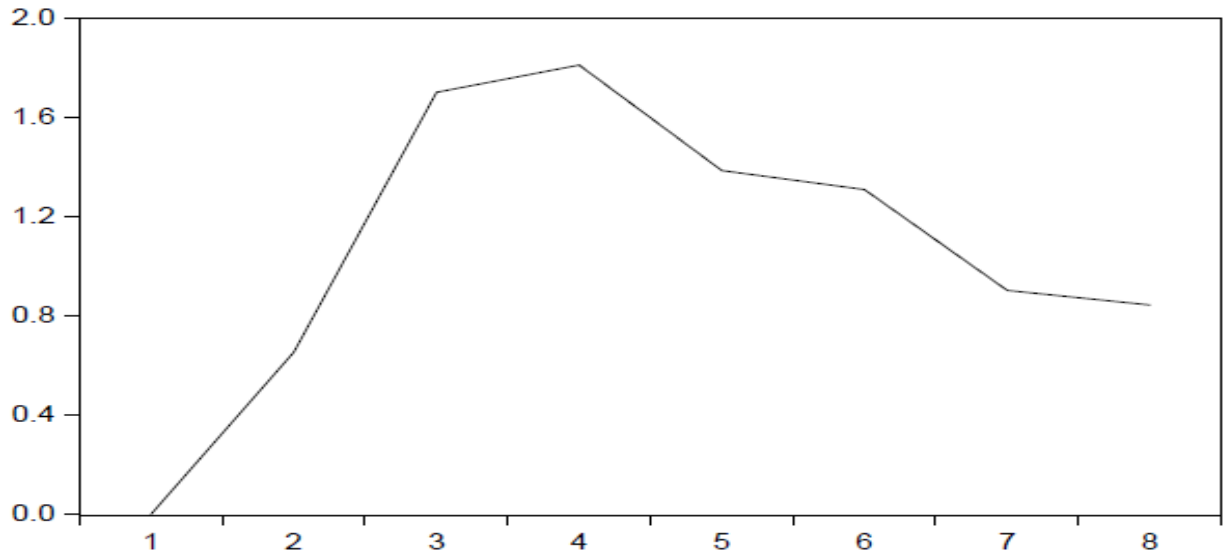
Prema dobivenim rezultatima (Tablica 15.) može se vidjeti, na temelju ekonometrijske analize za kratki rok, kako na kretanje SBITOP burzovnog indeksa utječu varijable tečaj eura prema dolaru, indeks potrošačkih cijena, kratkoročne kamatne stope i cijena nafte. U dugom roku može se vidjeti kako nijedna varijabla nema utjecaj na kretanje indeksa. Na grafikonu 13. prikazan je impulsni odgovor varijable SBITOP indeks na povećanje cijene nafte. U usporedbi sa prethodnim impulsnim odgovorima (DAX, CAC40 i ATX indeksi), može se vidjeti drukčije ponašanje impulsne funkcije, koja u ovom slučaju reagira pozitivno na povećanje cijene nafte.

Tablica 15: VECM procijenjen metodom najmanjih kvadrata, Slovenija

	Koeficijent	St. Greška	t-Statistic	Prob.		Koeficijent	St. Greška	t-Statistic	Prob.
C(1)	0.01	0.11	0.13	0.90	**C(43)**	-0.01	0.61	-0.01	0.99
C(2)	2.26	1.43	1.58	0.13	**C(44)**	-0.08	0.59	-0.14	0.89
C(3)	0.07	0.76	0.10	0.93	**C(45)**	-0.10	0.54	-0.19	0.85
C(4)	0.51	0.43	1.18	0.25	**C(46)**	-0.03	0.48	-0.05	0.96
C(5)	-0.02	0.03	-0.61	0.55	**C(47)**	-0.01	0.43	-0.02	0.98
C(6)	-0.01	0.14	-0.10	0.92	**C(48)**	0.11	0.39	0.28	0.78
C(7)	-0.33	0.22	-1.48	0.15	**C(49)**	0.12	0.32	0.36	0.72
C(8)	-0.15	0.23	-0.67	0.51	**C(50)**	0.06	0.19	0.35	0.73
C(9)	**-0.54**	**0.25**	**-2.12**	**0.04**	**C(51)**	0.02	0.07	0.26	0.80
C(10)	-0.30	0.24	-1.29	0.21	**C(52)**	0.05	0.06	0.77	0.45
C(11)	-0.06	0.19	-0.33	0.74	**C(53)**	-0.01	0.07	-0.20	0.84
C(12)	0.11	0.15	0.72	0.48	**C(54)**	-0.11	0.07	-1.55	0.13
C(13)	0.08	0.19	0.42	0.68	**C(55)**	0.01	0.06	0.16	0.87
C(14)	-0.02	0.17	-0.14	0.89	**C(56)**	**-0.11**	**0.06**	**-1.87**	**0.07**
C(15)	0.07	0.15	0.45	0.66	**C(57)**	-0.04	0.06	-0.57	0.57
C(16)	-0.11	0.18	-0.59	0.56	**C(58)**	-0.01	0.07	-0.15	0.88
C(17)	0.00	0.20	-0.01	0.99	**C(59)**	-0.08	0.06	-1.33	0.20
C(18)	**-5.98**	**3.41**	**-1.75**	**0.09**	**C(60)**	-0.03	0.06	-0.42	0.68
C(19)	-4.08	3.61	-1.13	0.27	**C(61)**	0.09	0.05	1.80	0.08
C(20)	-3.31	3.62	-0.91	0.37	**C(62)**	0.10	0.17	0.60	0.55
C(21)	-4.06	3.79	-1.07	0.29	**C(63)**	0.25	0.16	1.55	0.13
C(22)	-4.52	3.07	-1.47	0.15	**C(64)**	0.06	0.17	0.34	0.74
C(23)	-3.98	2.97	-1.34	0.19	**C(65)**	0.02	0.15	0.16	0.88
C(24)	-1.35	3.17	-0.43	0.67	**C(66)**	0.17	0.13	1.31	0.20
C(25)	-3.66	3.63	-1.01	0.32	**C(67)**	0.02	0.14	0.14	0.89
C(26)	**-6.27**	**3.68**	**-1.70**	**0.10**	**C(68)**	0.09	0.12	0.71	0.48
C(27)	-1.60	3.26	-0.49	0.63	**C(69)**	0.09	0.12	0.79	0.44
C(28)	-0.42	2.79	-0.15	0.88	**C(70)**	**0.30**	**0.13**	**2.36**	**0.03**
C(29)	-0.54	0.68	-0.79	0.44	**C(71)**	**0.35**	**0.15**	**2.33**	**0.03**
C(30)	-0.08	0.57	-0.14	0.89	**C(72)**	0.13	0.15	0.84	0.41
C(31)	-0.09	0.54	-0.16	0.87	**C(73)**	1.01	2.42	0.42	0.68
C(32)	-0.06	0.44	-0.13	0.90	**C(74)**	3.75	2.43	1.54	0.14
C(33)	-0.02	0.41	-0.06	0.96	**C(75)**	2.71	2.68	1.01	0.32
C(34)	0.23	0.49	0.47	0.64	**C(76)**	2.67	2.27	1.18	0.25
C(35)	0.13	0.40	0.34	0.74	**C(77)**	2.42	2.23	1.09	0.29
C(36)	**0.70**	**0.35**	**2.03**	**0.05**	**C(78)**	0.08	1.94	0.04	0.97
C(37)	0.14	0.35	0.40	0.69	**C(79)**	0.71	1.55	0.46	0.65
C(38)	0.26	0.26	0.98	0.34	**C(80)**	-0.06	1.61	-0.04	0.97
C(39)	0.30	0.29	1.03	0.31	**C(81)**	-0.47	1.67	-0.28	0.78
C(40)	-0.38	0.43	-0.89	0.38	**C(82)**	-0.08	1.71	-0.05	0.96
C(41)	-0.26	0.46	-0.56	0.58	**C(83)**	-1.03	1.35	-0.76	0.45
C(42)	-0.13	0.54	-0.25	0.81	**C(84)**	-0.73	2.81	-0.26	0.80

R-squared	0.91	Mean dependent var	-1.67
Adjusted R-squared	0.61	S.D. dependent var	6.35
S.E. of regression	3.97	Akaike info criterion	5.65
Sum squared resid	377.88	Schwarz criterion	7.73
Log likelihood	-220.88	Hannan-Quinn criter.	6.49
F-statistic	3.01	Durbin-Watson stat	2.40

Izvor: Izrada autora.



Grafikon 13: Impulsni odgovor SBITOP indeksa na povećanje cijene nafte

Izvor: Izrada autora.

Na temelju provedene analize za Sloveniju možemo prihvatiti prvu hipitezu, te zaključiti kako povećanje cijene nafte na svjetskom tržištu ima utjecaja na kretanje burzovnog indeksa, u kratkom roku. Impulsni odgovor podupire potonju tezu. Druga hipoteza biti će analizirana u poglavlju „3.4. Rasprava istraživanja“.

3.3.5. Hrvatska

U sljedećem koraku je provedena analiza za Repubiku Hrvatsku. Prema dobivenim rezultatima, niti jedna od promatranih varijabli ne pokazuje jedinični korjen, te možemo zaključiti kako su sve varijable stacionarne na razini I(1), (Tablica 16.). Optimalan broj pomaka iznosi 12 prema LR, FPE i AIC informacijskim kriterijima, dostupno u tablici P1, no kao i u prethodnim analizama, broj pomaka je potrebno umanjiti za 1, te on u analizi iznosi 11.

Tablica 16: Rezultati Phillips-Perronovog testa, Hrvatska

Hrvatska - Phillips-Perron test jediničnog korjena D(X)					
Null Hipoteza: D(X) ima jedinični korjen Egzogena: Konstanta					
D(burzovni indeks - CROBEX)	Adj. t-Stat	Prob.*	D(indeks potrošačkih cijena)	Adj. t-Stat	Prob.*
Phillips-Perron test statistic	-9.84	0.00	Phillips-Perron test statistic	-7.42	0.00
D(devizni tečaj)	Adj. t-Stat	Prob.*	D(indeks industrijske proizv.)	Adj. t-Stat	Prob.*
Phillips-Perron test statistic	-7.91	0.00	Phillips-Perron test statistic	-27.90	0.00
D(kratkor. kamatna stopa)	Adj. t-Stat	Prob.*	*MacKinnon (1996) one-sided p-values		
Phillips-Perron test statistic	-6.96	0.00			
Test critical values: 1% level	-3.49				
5% level	-2.89				
10% level	-2.58				

Izvor: Izrada autora.

Prema rezultatima provedenog Grangerova testa vidi se kako na CROBEX burzovni indeks utjecaj imaju kretanja varijabli kratkoročne kamatne stope, devizni tečaj (odnos kuna i dolar) i cijena nafte, podatci dostupni u tablici P2. Johansenov test kointegracije pokazuje kako postoji postoji šest kointegracijskih vektora. Test kointegracije dostupan je u tablici 17.

Tablica 17: Johansenov test, Hrvatska

Unrestricted Cointegration Rank Test (Trace)				
Hypothesized No. of CE(s)	**Eigenvalue**	**Trace Statistic**	**0.05 Critical value**	**Prob.** ***
None *	0.84	506.59	125.62	0.00
At most 1 *	0.57	301.97	95.75	0.00
At most 2 *	0.54	210.04	69.82	0.00
At most 3 *	0.46	126.93	47.86	0.00
At most 4 *	0.28	59.80	29.80	0.00
At most 5 *	0.20	24.25	15.50	0.00
At most 6	0.00	0.05	3.84	0.83
Trace test indicates 6 cointegrating eqn(s) at the 0.05 level * denotes rejection of the hypothesis at the 0.05 level **MacKinnon-Haug-Michelis (1999) p-values				

Izvor: Izrada autora.

Temeljem dobivenih rezultata procjenjena je jednadžba oblika:

D(INDX) = C(1)*(INDX(-1) – 4.47*QO(-1) + 556.67) + C(2)*(CPI(-1) – 1.51*QO(-1) -52.33) + C(3)*(EXR(-1) – 4.15*QO(-1) + 317.97) + C(4)*(IP(-1) - 1.22*QO(-1) – 238.20) + C(5)*(IR(-1) + 16.31*QO(-1) – 1804.35) + C(6)*(PO(-1) + 0.28*QO(-1) - 83.35) + C(7)*D(INDX(-1) + ... + C(17)*D(INDX(-11) + C(18)*D(CPI(-1) + ... + C(28)*D(CPI(-11) + C(29) * D(EXR(-1) + ... + C(39) * D(EXR(-11) + C(40) * D(IP(-1) + ... + C(50) * D(IP(-11) + C(51)*D(IR(-1) + ... + C(61) * D(IR(-11) + C(62)*D(PO(-1) + ... + C(72)*D(QO(-11) + C(73)*D(PO(-1) + ... + C(83) * D(QO(-11) + C(84)., (9.)

te na temelju procijenjenih koefcijenata (Tablica 18.) koji su statistički značajni glasi:

D(INDX) = -0.43*(INDX(-1) – 4.47*QO(-1) + 556.67) - 1.12*(EXR(-1) – 4.15*QO(-1) + 317.97) – 0.42*(PO(-1) + 0.28*QO(-1) - 83.35) - 0.31*(INDX(-2) - 0.50*(INDX(-3) + 7.03*CPI(-1) + 5.31*CPI(-2) + 7.00*CPI(-3) + 8.77*CPI(-4) + 8.70*CPI(-6) + 6.01*CPI(-7) + 6.10*CPI(-8) - 0.89*EXR(-8) + 0.09*IR(-7) + 0.51*PO(-1) + 0.39*PO(-2) + 0.32*PO(-3) - 8.53, (10.)

gdje se oznaka INDX odnosi na index CROBEX, CPI na indeks potrošačkih cijena, EXR na tečaj eura, IP na industrijsku proizvodnju, IR na kratkoročnu kamatnu stopu, PO na cijenu, a QO količinu nafte. Procjenjeni koeficijenti jednadžbe nalaze se u tablici 18., te su statistički značajni koeficijenti podebljani. Granica statističke značajnosti je 10%, odnosno 0,10.

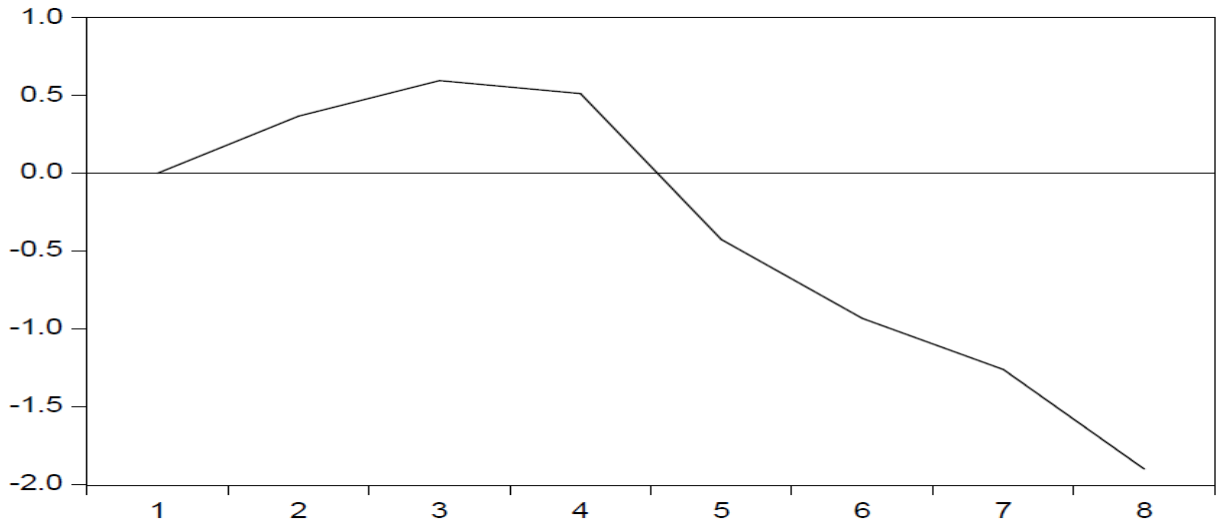
Prema dobivenim rezultatima (Tablica 18.) može se vidjeti, za kratki rok vrijedi, da na kretanje CROBEX burzovnog indeksa utječu varijable indeks potrošačkih cijena, tečaj kune prema dolaru, kratkoročne kamatne stope i cijena nafte, te konstanta. U analizi utjecaja varijabli u dugom roku na varijablu CROBEX utjecaj imaju tečaj kune prema dolaru, cijena i količina proizvedene nafte, te konstantni član. Grafikon 14. prikazuje impulsni odgovor CROBEX-a na naftni šok (povećanje cijene), te možemo zaključiti kako se u ovom slučaju vidi pozitivna reakcija indeksa na porast cijene nafte do petog razdoblja, kada utjecaj prelazi u negativan.

Tablica 18: VECM procijenjen metodom najmanjih kvadrata, Hrvatska

	Koeficijent	St. Greška	t-Statistic	Prob.		Koeficijent	St. Greška	t-Statistic	Prob.
C(1)	**-0.43**	**0.10**	**-4.26**	**0.00**	**C(43)**	1.18	0.81	1.46	0.16
C(2)	-0.97	1.25	-0.77	0.45	**C(44)**	0.91	0.70	1.30	0.21
C(3)	**-1.12**	**0.45**	**-2.47**	**0.02**	**C(45)**	0.72	0.66	1.09	0.29
C(4)	-1.79	1.12	-1.60	0.12	**C(46)**	0.54	0.56	0.96	0.35
C(5)	-0.03	0.04	-0.65	0.52	**C(47)**	0.38	0.45	0.84	0.41
C(6)	**-0.42**	**0.18**	**-2.39**	**0.02**	**C(48)**	0.34	0.35	0.96	0.35
C(7)	-0.10	0.14	-0.71	0.48	**C(49)**	0.38	0.32	1.21	0.24
C(8)	**-0.31**	**0.15**	**-2.11**	**0.05**	**C(50)**	0.24	0.20	1.19	0.25
C(9)	**-0.50**	**0.15**	**-3.28**	**0.00**	**C(51)**	0.05	0.06	0.84	0.41
C(10)	-0.02	0.14	-0.12	0.90	**C(52)**	0.07	0.07	1.10	0.28
C(11)	0.08	0.15	0.58	0.57	**C(53)**	0.07	0.06	1.09	0.29
C(12)	-0.25	0.16	-1.64	0.11	**C(54)**	0.05	0.06	0.82	0.42
C(13)	-0.05	0.14	-0.34	0.73	**C(55)**	0.02	0.05	0.37	0.71
C(14)	0.23	0.14	1.62	0.12	**C(56)**	0.02	0.05	0.41	0.69
C(15)	-0.06	0.17	-0.37	0.72	**C(57)**	**0.09**	**0.05**	**1.81**	**0.08**
C(16)	0.17	0.15	1.11	0.28	**C(58)**	0.08	0.05	1.44	0.16
C(17)	0.14	0.13	1.05	0.31	**C(59)**	-0.01	0.05	-0.13	0.89
C(18)	**7.03**	**2.90**	**2.43**	**0.02**	**C(60)**	-0.01	0.04	-0.14	0.89
C(19)	**5.31**	**2.32**	**2.29**	**0.03**	**C(61)**	-0.04	0.05	-0.90	0.38
C(20)	**7.00**	**2.89**	**2.42**	**0.02**	**C(62)**	**0.51**	**0.20**	**2.49**	**0.02**
C(21)	**8.77**	**2.63**	**3.34**	**0.00**	**C(63)**	**0.39**	**0.21**	**1.91**	**0.07**
C(22)	4.30	2.57	1.67	0.11	**C(64)**	**0.32**	**0.17**	**1.88**	**0.07**
C(23)	**8.70**	**2.64**	**3.30**	**0.00**	**C(65)**	0.18	0.19	0.99	0.33
C(24)	**6.01**	**3.09**	**1.94**	**0.06**	**C(66)**	0.14	0.21	0.66	0.52
C(25)	**6.10**	**2.39**	**2.55**	**0.02**	**C(67)**	0.13	0.19	0.66	0.51
C(26)	3.54	2.65	1.34	0.19	**C(68)**	-0.19	0.16	-1.20	0.24
C(27)	-0.03	2.24	-0.01	0.99	**C(69)**	-0.04	0.18	-0.23	0.82
C(28)	2.28	2.46	0.93	0.36	**C(70)**	-0.25	0.17	-1.49	0.15
C(29)	0.79	0.48	1.66	0.11	**C(71)**	0.02	0.18	0.09	0.93
C(30)	0.62	0.56	1.12	0.27	**C(72)**	-0.05	0.14	-0.34	0.74
C(31)	-0.06	0.46	-0.14	0.89	**C(73)**	-0.63	2.03	-0.31	0.76
C(32)	0.15	0.54	0.29	0.78	**C(74)**	0.17	1.94	0.09	0.93
C(33)	-0.59	0.62	-0.95	0.35	**C(75)**	-0.06	1.85	-0.03	0.98
C(34)	-0.64	0.56	-1.14	0.26	**C(76)**	1.57	1.82	0.86	0.40
C(35)	-0.10	0.58	-0.17	0.86	**C(77)**	0.47	2.10	0.22	0.83
C(36)	**-0.89**	**0.39**	**-2.30**	**0.03**	**C(78)**	1.64	2.15	0.76	0.45
C(37)	-0.50	0.45	-1.12	0.27	**C(79)**	0.49	1.78	0.28	0.78
C(38)	-0.27	0.42	-0.64	0.53	**C(80)**	1.02	1.60	0.63	0.53
C(39)	-0.05	0.37	-0.15	0.88	**C(81)**	1.54	1.52	1.01	0.32
C(40)	1.50	1.00	1.49	0.15	**C(82)**	-1.33	1.86	-0.71	0.48
C(41)	1.28	0.94	1.36	0.19	**C(83)**	-1.15	1.64	-0.70	0.49
C(42)	1.21	0.85	1.42	0.17	**C(84)**	**-8.53**	**1.94**	**-4.39**	**0.00**

R-squared	0.94	Mean dependent var	-1.36
Adjusted R-squared	0.71	S.D. dependent var	7.82
S.E. of regression	4.21	Akaike info criterion	5.76
Sum squared resid	424.27	Schwarz criterion	7.85
Log likelihood	-227.13	Hannan-Quinn criter.	6.61
F-statistic	4.17	Durbin-Watson stat	2.15

Izvor: Izrada autora.



Grafikon 14: Impulsni odgovor CROBEX indeksa na povećanje cijene nafte

Izvor: Izrada autora.

Temeljem provedene ekonometrijske analize može se prihvatiti prva hipoteza da postoji utjecaj cijena nafte na burzovni indeks CROBEX u kratkom i dugom roku u Hrvatskoj. Druga hipoteza biti će analizirana u daljnjem dijelu rada („3.4. Rasprava istraživanja“).

3.3.6. Italija

Prema dobivenim rezultatima za Italiju, niti jedna od promatranih varijabli ne pokazuje jedinični korjen, te možemo zaključiti kako su sve varijable stacionarne na razini I(1), rezultati dostupni u tablici 19. Optimalan broj pomaka iznosi 12 prema LR, FPE, AIC i HQ informacijskim kriterijima (Tablica P1.), no kao i u prethodnim analizama, broj pomaka se smanjio za 1, na 11.

Rezultati Grangerova testa ne pronalaze direktan utjecaj niti jedne varijable na kretanje burzovnog indeksa FTSE MIB (Tablica P2.) Johansenov test kointegracije ukazuje na postojanje pet kointegracijskih veza (Tablica 20.).

Tablica 19: Rezultati Phillips-Perronovog testa, Italija

Italija - Phillips-Perron test jediničnog korjena D(X)					
Null Hipoteza: D(X) ima jedinični korjen Egzogena: Konstanta					
D(burzovni indeks - FTSE_MIB)	Adj. t-Stat	Prob.*	D(indeks potrošačkih cijena)	Adj. t-Stat	Prob.*
Phillips-Perron test statistic	-9.25	0.00	Phillips-Perron test statistic	-10.00	0.00
D(devizni tečaj)	Adj. t-Stat	Prob.*	D(indeks industrijske proizv.)	Adj. t-Stat	Prob.*
Phillips-Perron test statistic	-8.46	0.00	Phillips-Perron test statistic	-31.00	0.00
D(kratkor. kamatna stopa)	Adj. t-Stat	Prob.*	*MacKinnon (1996) one-sided p-values		
Phillips-Perron test statistic	-4.66	0.00			
Test critical values: 1% level	-3.49				
5% level	-2.89				
10% level	-2.58				

Izvor: Izrada autora.

Tablica 20: Johansenov test, Italija

Unrestricted Cointegration Rank Test (Trace)				
Hypothesized No. of CE(s)	**Eigenvalue**	**Trace Statistic**	**0.05 Critical value**	**Prob.** ***
None *	0.80	452.93	125.62	0.00
At most 1 *	0.72	278.52	95.75	0.00
At most 2 *	0.44	142.59	69.82	0.00
At most 3 *	0.35	80.65	47.86	0.00
At most 4 *	0.19	34.07	29.80	0.02
At most 5	0.08	10.53	15.50	0.24
At most 6	0.01	0.96	3.84	0.33
Trace test indicates 5 cointegrating eqn(s) at the 0.05 level * denotes rejection of the hypothesis at the 0.05 level **MacKinnon-Haug-Michelis (1999) p-values				

Izvor: Izrada autora.

Temeljem rezultata Johansenova testa, procijenjena je sljedeća jednadžba:

D(INDX) = C(1)*(INDX(-1) - 0.80*PO(-1) + 5.94*QO(-1) - 620.07) + C(2)*(CPI(-1) - 0.04*PO(-1) - 1.31*QO(-1) + 35.36) + C(3)*(EXR(-1) - 0.14*PO(-1) - 2.96*QO(-1) + 213.25) + C(4)*(IP(-1) - 0.36*PO(-1) + 1.60*QO(-1) - 238.42) + C(5)*(IR(-1) - 7.68*PO(-1) + 46.68*QO(-1) - 4136.98) + C(6)*D(INDX(-1) + ... + C(16)*D(INDX(-11) + C(17)*D(CPI(-1) + ... + C(27)*D(CPI(-11) + C(28)*D(EXR(-1) + ... + C(38)*D(EXR(-11) + C(39)*D(IP(-1) + ... + C(49)*D(IP(-11) + C(50)*D(IR(-1) + ... + C(60)*D(IR(-11) + C(61)*D(PO(-1) + ... + C(71)*D(QO(-11) + C(72)*D(PO(-1) + ... + C(82)*D(QO(-11) + C(83)., (11.)

te na temelju procijenjenih koefcijenata (Tablica 21.) koji su statistički značajni glasi:

D(INDX) = -1.00*(INDX(-1) - 0.80*PO(-1) + 5.94*QO(-1) - 620.07) + 17.14*(CPI(-1) - 0.04*PO(-1) - 1.31*QO(-1) + 35.36) – 4.04*(EXR(-1) - 0.14*PO(-1) - 2.96*QO(-1) + 213.25) + 9.87*(IP(-1) - 0.36*PO(-1) + 1.60*QO(-1) - 238.42) – 0.16*(IR(-1) - 7.68*PO(-1) + 46.68*QO(-1) - 4136.98) + 0.54*D(INDX(-1)) + 0.63*D(INDX(-3)) + 1.21*D(INDX(-4)) + 0.72*D(INDX(-5)) + 0.59*D(INDX(-6)) + 0.64*D(INDX(-7)) + 0.68*D(INDX(-8)) + 1.10*D(INDX(-9)) + 0.85*D(INDX(-10)) + 0.66*D(INDX(-11)) – 39.07 *D(CPI(-10)) – 29.53*D(CPI(-11)) – 17.72 *D(CPI(-5)) – 18.92*D(CPI(-6)) + 3.72*D(EXR(-1)) + 3.15*D(EXR(-2)) + 3.19*D(EXR(-3)) + 1.87*D(EXR(-4)) + 1.57*D(EXR(-5)) - 9.23*D(IP(-1)) - 8.35 *D(IP(-2)) – 7.37*D(IP(-3)) – 6.47*D(IP(-4)) – 5.61*D(IP(-5)) – 4.78*D(IP(-6)) – 4.10*D(IP(-7)) – 3.41*D(IP(-8)) – 2.46*D(IP(-9)) – 1.76*D(IP(-10)) – 0.90*D(IP(-11)) + 0.28*D(IR(-1)) + 0.21*D(IR(-2)) + 1.43*D(PO(-1)) + 1.24*D(PO(-2)) + 0.83*D(PO(-3)) – 0.40*D(PO(-4)) + 10.87*D(QO(-1)) + 10.65*D(QO(-2)) + 8.97*D(QO(-3)) + 12.12*D(QO(-4)) + 11.60*D(QO(-5)) + 10.37*D(QO(-6)) + 11.68*D(QO(-7)) + 7.41*D(QO(-10)), (12.)

gdje se oznaka INDX odnosi na index FTSE MIB, CPI na indeks potrošačkih cijena, EXR na tečaj eura, IP na industrijsku proizvodnju, IR na kratkoročnu kamatnu stopu, PO na cijenu, a QO količinu nafte. Procjenjeni koeficijenti jednadžbe nalaze se u tablici 21., te su statistički značajni koeficijenti podebljani. Granica statističke značajnosti je 10%, odnosno 0,10.

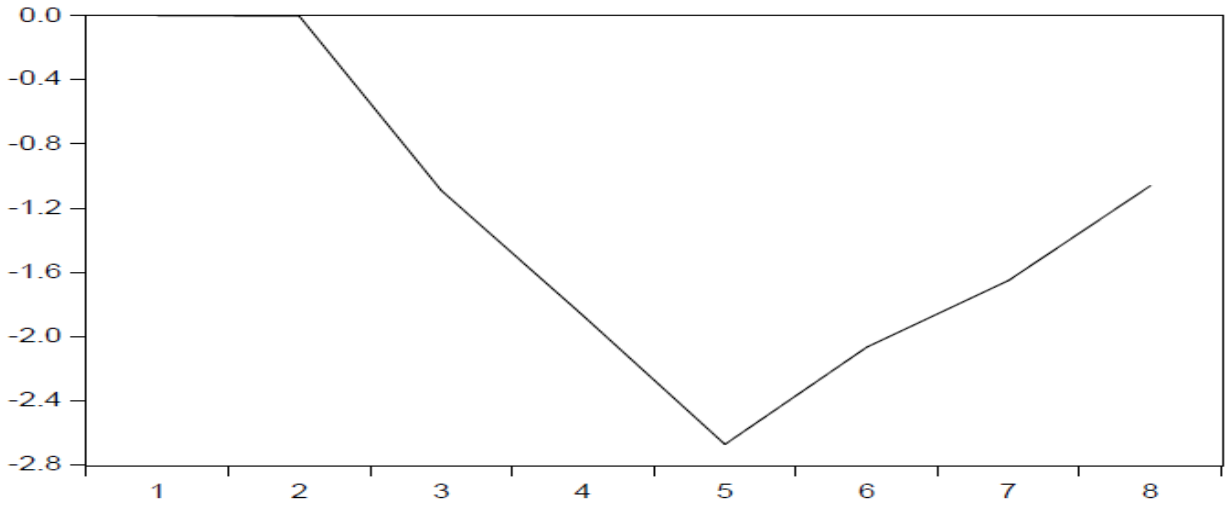
Tablica 21: VECM procijenjen metodom najmanjih kvadrata, Italija

	Koeficijent	St. Greška	t-Statistic	Prob.		Koeficijent	St. Greška	t-Statistic	Prob.
C(1)	**-1.00**	**0.31**	**-3.23**	**0.00**	**C(43)**	**-5.61**	**2.02**	**-2.78**	**0.01**
C(2)	**17.14**	**6.66**	**2.57**	**0.02**	**C(44)**	**-4.78**	**1.75**	**-2.73**	**0.01**
C(3)	**-4.04**	**1.36**	**-2.98**	**0.01**	**C(45)**	**-4.10**	**1.49**	**-2.75**	**0.01**
C(4)	**9.87**	**3.13**	**3.15**	**0.00**	**C(46)**	**-3.41**	**1.21**	**-2.81**	**0.01**
C(5)	**-0.16**	**0.08**	**-2.00**	**0.06**	**C(47)**	**-2.46**	**0.89**	**-2.76**	**0.01**
C(6)	**0.54**	**0.31**	**1.75**	**0.09**	**C(48)**	**-1.76**	**0.59**	**-2.97**	**0.01**
C(7)	0.44	0.30	1.46	0.16	**C(49)**	**-0.90**	**0.29**	**-3.06**	**0.01**
C(8)	**0.63**	**0.32**	**1.99**	**0.06**	**C(50)**	**0.28**	**0.11**	**2.54**	**0.02**
C(9)	**1.21**	**0.33**	**3.63**	**0.00**	**C(51)**	**0.21**	**0.09**	**2.26**	**0.03**
C(10)	**0.72**	**0.28**	**2.54**	**0.02**	**C(52)**	0.08	0.08	1.04	0.31
C(11)	**0.59**	**0.33**	**1.77**	**0.09**	**C(53)**	0.06	0.09	0.62	0.54
C(12)	**0.64**	**0.32**	**2.00**	**0.06**	**C(54)**	0.08	0.09	0.98	0.34
C(13)	**0.68**	**0.33**	**2.05**	**0.05**	**C(55)**	0.00	0.08	-0.06	0.95
C(14)	**1.10**	**0.38**	**2.93**	**0.01**	**C(56)**	0.07	0.07	0.96	0.35
C(15)	**0.85**	**0.35**	**2.40**	**0.02**	**C(57)**	-0.01	0.08	-0.17	0.87
C(16)	**0.66**	**0.27**	**2.39**	**0.02**	**C(58)**	0.01	0.07	0.17	0.86
C(17)	**-39.07**	**11.41**	**-3.42**	**0.00**	**C(59)**	-0.02	0.08	-0.28	0.78
C(18)	**-29.53**	**10.84**	**-2.72**	**0.01**	**C(60)**	-0.13	0.08	-1.61	0.12
C(19)	-1.25	6.39	-0.20	0.85	**C(61)**	**1.43**	**0.48**	**2.96**	**0.01**
C(20)	3.22	8.11	0.40	0.69	**C(62)**	**1.24**	**0.44**	**2.79**	**0.01**
C(21)	**-17.72**	**8.45**	**-2.10**	**0.05**	**C(63)**	**0.83**	**0.37**	**2.23**	**0.03**
C(22)	**-18.92**	**8.08**	**-2.34**	**0.03**	**C(64)**	0.13	0.34	0.37	0.71
C(23)	2.73	8.40	0.32	0.75	**C(65)**	0.46	0.36	1.30	0.20
C(24)	-7.91	8.08	-0.98	0.34	**C(66)**	0.59	0.30	1.98	0.06
C(25)	10.49	9.01	1.17	0.25	**C(67)**	-0.09	0.23	-0.38	0.71
C(26)	4.02	8.03	0.50	0.62	**C(68)**	**-0.40**	**0.21**	**-1.90**	**0.07**
C(27)	-9.72	7.34	-1.32	0.20	**C(69)**	-0.05	0.26	-0.19	0.85
C(28)	**3.72**	**1.34**	**2.78**	**0.01**	**C(70)**	-0.46	0.22	-2.13	0.04
C(29)	**3.15**	**1.19**	**2.65**	**0.01**	**C(71)**	-0.14	0.23	-0.62	0.54
C(30)	**3.19**	**1.11**	**2.88**	**0.01**	**C(72)**	**10.87**	**3.91**	**2.78**	**0.01**
C(31)	**1.87**	**1.03**	**1.82**	**0.08**	**C(73)**	**10.65**	**4.03**	**2.64**	**0.01**
C(32)	**1.57**	**0.89**	**1.76**	**0.09**	**C(74)**	**8.97**	**3.86**	**2.33**	**0.03**
C(33)	1.49	0.95	1.57	0.13	**C(75)**	**12.12**	**3.85**	**3.14**	**0.00**
C(34)	0.77	0.71	1.08	0.29	**C(76)**	**11.60**	**3.77**	**3.08**	**0.01**
C(35)	0.79	0.71	1.11	0.28	**C(77)**	**10.37**	**4.18**	**2.48**	**0.02**
C(36)	0.51	0.68	0.75	0.46	**C(78)**	**11.68**	**3.88**	**3.01**	**0.01**
C(37)	0.44	0.59	0.74	0.46	**C(79)**	5.04	3.54	1.42	0.17
C(38)	0.35	0.53	0.67	0.51	**C(80)**	4.74	2.99	1.59	0.12
C(39)	**-9.23**	**2.92**	**-3.16**	**0.00**	**C(81)**	**7.41**	**3.48**	**2.13**	**0.04**
C(40)	**-8.35**	**2.72**	**-3.07**	**0.01**	**C(82)**	3.00	2.78	1.08	0.29
C(41)	**-7.37**	**2.50**	**-2.95**	**0.01**	**C(83)**	-3.17	5.70	-0.56	0.58
C(42)	**-6.47**	**2.28**	**-2.83**	**0.01**					

R-squared	0.82	Mean dependent var	-0.82
Adjusted R-squared	0.21	S.D. dependent var	6.49
S.E. of regression	5.78	Akaike info criterion	6.42
Sum squared resid	834.06	Schwarz criterion	8.48
Log likelihood	-263.63	Hannan-Quinn criter.	7.26
F-statistic	1.34	Durbin-Watson stat	1.87

Izvor: Izrada autora.

Rezultati analize (Tablica 21.) sugeriraju kako u kratkom roku kretanje burzovnog indeksa ovisi o kretanju indeksa potrošačkih cijena, tečaju eura prema dolaru, indeksu industrijske proizvodnje, kratkoročnim kamatnim stopama, cijeni i količini nafte. U dugom roku, prema koeficijentima 1, 3 i 5 možemo zaključiti da kretanje burzovnog indeksa ovisi o kretanju varijabli deviznog tečaja, cijeni nafte, kratkoročnim kamatnim stopama, količini nafte i konstanti. Grafikon 15. prikazuje impulsni odgovor FTSE MIB indeksa na naftni šok (povećanje cijene), te možemo zaključiti kako navedeni indeks reagira na isti način kao i DAX, CAC40 i ATX indeksi.



Grafikon 15: Impulsni odgovor FTSE MIB indeksa na povećanje cijene nafte

Izvor: Izrada autora.

Temeljem provedenog istraživanja, prihvaća se prva hipoteza o postojanju veze između FTSE MIB burzovnog indeksa i cijene nafte, u kratkom i dugom roku za Italiju. Analiza druge hipoteze biti će prikazana u daljnjem dijelu rada.

3.3.7. Norveška

U nastavku se analizira Norveška kao jedna od zanačajnih zemalja izvoznica nafte. Prema dobivenim rezultatima, niti jedna od promatranih varijabli ne pokazuje jedinični korjen (Tabica 22.), te možemo zaključiti kako su sve varijable stacionarne na razini I(1). Optimalan broj

pomaka iznosi 12 prema LR, FPE, AIC i HQ informacijskim kriterijima (Tablica P1.), no kao i u prethodnim analizama, uzet je broj od 11 pomaka zbog uvjeta „p-1“.

Tablica 22: Rezultati Phillips-Perronovog testa, Norveška

Norveška - Phillips-Perron test jediničnog korjena D(X)					
Null Hipoteza: D(X) ima jedinični korjen Egzogena: Konstanta					
D(burzovni indeks - OSEX)	Adj. t-Stat	Prob.*	D(indeks potrošačkih cijena)	Adj. t-Stat	Prob.*
Phillips-Perron test statistic	-9.07	0.00	Phillips-Perron test statistic	-11.99	0.00
D(devizni tečaj)	Adj. t-Stat	Prob.*	D(indeks industrijske proizv.)	Adj. t-Stat	Prob.*
Phillips-Perron test statistic	-6.96	0.00	Phillips-Perron test statistic	-24.91	0.00
D(kratkor. kamatna stopa)	Adj. t-Stat	Prob.*	*MacKinnon (1996) one-sided p-values		
Phillips-Perron test statistic	-4.43	0.00			
Test critical values: 1% level	-3.49				
5% level	-2.89				
10% level	-2.58				

Izvor: Izrada autora.

Grangerov testest ukazuje da na kretanje OSX-a utječu varijable kratkoročne kamatne stope, indeks industrijske proizvodnje, cijena i količina nafte (Tablica P2.). Johansenov test kointegracije pokazuje kako postoji postoji šest kointegracijskih vektora. Test kointegracije dostupan je u tablici 23.

Tablica 23: Johansenov test kointegracije, Norveška

Unrestricted Cointegration Rank Test (Trace)				
Hypothesized No. of CE(s)	**Eigenvalue**	**Trace Statistic**	**0.05 Critical value**	**Prob.** ***
None *	0.80	471.81	125.62	0.00
At most 1 *	0.72	298.75	95.75	0.00
At most 2 *	0.48	161.66	69.82	0.00
At most 3 *	0.30	90.43	47.86	0.00
At most 4 *	0.22	51.77	29.80	0.00
At most 5 *	0.20	24.75	15.50	0.00
At most 6	0.01	1.07	3.84	0.30
Trace test indicates 6 cointegrating eqn(s) at the 0.05 level * denotes rejection of the hypothesis at the 0.05 level **MacKinnon-Haug-Michelis (1999) p-values				

Izvor: Izrada autora.

Temeljem Grangerovog i Johansenovog testa procjenjena je jednadžba oblika:

D(INDX) = C(1)*(INDX(-1) – 5.69*QO(-1) + 464.12) + C(2)*(CPI(-1) – 1.31*QO(-1) - 31.32) + C(3)*(EXR(-1) – 5.42*QO(-1) + 450.66) + C(4)*(IP(-1) - 0.28*QO(-1) – 117.55) + C(5)*(IR(-1) + 6.22*QO(-1) – 756.66) + C(6)*(PO(-1) + 6.96 *QO(-1) - 834.15) + C(7)*D(INDX(-1) + ... + C(17)*D(INDX(-11) + C(18)*D(CPI(-1) + ... + C(28)*D(CPI(-11) + C(29) * D(EXR(-1) + ... + C(39) * D(EXR(-11) + C(40) * D(IP(-1) + ... + C(50) * D(IP(-11) + C(51)*D(IR(-1) + ... + C(61) * D(IR(-11) + C(62)*D(PO(-1) + ... + C(72)*D(QO(-11) + C(73)*D(PO(-1) + ... + C(83) * D(QO(-11) + C(84)., (13.)

te na temelju procijenjenih koefcijenata (Tablica 24.) koji su statistički značajni glasi:

D(INDX) = -0.78*(INDX(-1) – 5.69*QO(-1) + 464.12) + 5.21*(CPI(-1) – 1.31*QO(-1) - 31.32) + 0.24*(IR(-1) + 6.22*QO(-1) – 756.66) + 1.06*D(INDX(-8)) + 0.62*D(INDX(-9)) - 12.44*D(CPI(-1)) - 9.69*D(CPI(-2)) + 6.49*D(CPI(-6)) + 10.25*D(CPI(-7)) + 11.81*D(CPI(-10)) + 1.61*D(EXR(-8)) + 0.95*D(EXR(-11)) – 0.49*D(IR(-10)) - 0.44* D(PO(-3)) - 0.43*D(PO(-5)) – 0.54* D(PO(-6)), (14.)

gdje se oznaka INDX odnosi na index OSX, CPI na indeks potrošačkih cijena, EXR na tečaj eura, IP na industrijsku proizvodnju, IR na kratkoročnu kamatnu stopu, PO na cijenu, a QO količinu nafte. Procjenjeni koeficijenti jednadžbe nalaze se u tablici 24., te su statistički značajni koeficijenti podebljani. Granica statističke značajnosti je 10%, odnosno 0,10.

Norveški OSX indeks (Tablica 24.) u kratkom roku ovisi o kretanju varijabli indeks potrošačkih cijena, tečaj krune prema dolaru, kratkoročnim kamatnim stopama i cijeni nafte. U dugom roku kretatanje indeksa (prema koeficijentu C(1)) ovisi o prijašnjim šokovima indeksa i količini nafte. Koeficijenti C(2) i C(5) su statistički značajni, ali su pozitivnog predznaka, te na temelju njih ne može se zaključiti da postoji utjecaj indeksa potrošačkih cijena i OSX-a, odnosno kratkoročnih kamatnih stopa i OSX-a, u dugom roku.

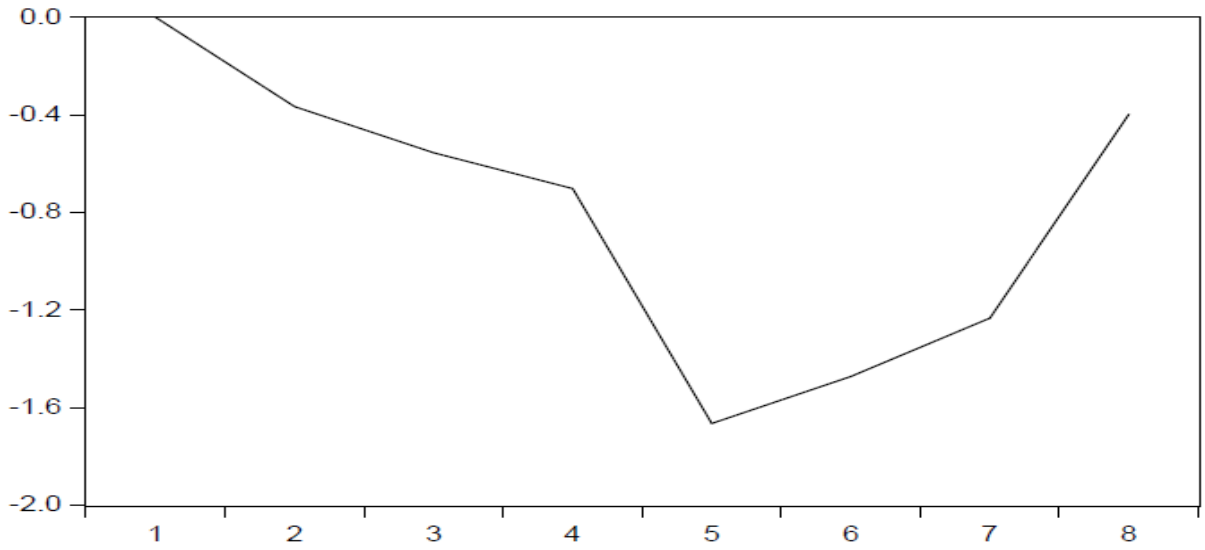
Tablica 24: VECM procijenjen metodom najmanjih kvadrata, Norveška

	Koeficijent	St. Greška	t-Statistic	Prob.		Koeficijent	St. Greška	t-Statistic	Prob.
C(1)	**-0.78**	**0.22**	**-3.50**	**0.00**	**C(43)**	-0.16	0.82	-0.20	0.84
C(2)	**5.21**	**1.80**	**2.89**	**0.01**	**C(44)**	0.23	0.68	0.34	0.74
C(3)	-1.00	0.85	-1.18	0.25	**C(45)**	0.16	0.60	0.26	0.80
C(4)	0.65	1.00	0.65	0.52	**C(46)**	0.41	0.55	0.75	0.46
C(5)	**0.24**	**0.13**	**1.78**	**0.09**	**C(47)**	0.60	0.48	1.24	0.23
C(6)	-0.09	0.24	-0.36	0.72	**C(48)**	0.02	0.45	0.03	0.97
C(7)	0.29	0.27	1.09	0.29	**C(49)**	-0.40	0.44	-0.90	0.38
C(8)	0.11	0.30	0.35	0.73	**C(50)**	-0.36	0.37	-0.96	0.35
C(9)	0.48	0.29	1.67	0.11	**C(51)**	0.19	0.21	0.92	0.37
C(10)	0.54	0.33	1.65	0.11	**C(52)**	-0.06	0.25	-0.22	0.83
C(11)	0.10	0.31	0.30	0.76	**C(53)**	0.15	0.24	0.63	0.54
C(12)	0.40	0.32	1.27	0.22	**C(54)**	0.25	0.23	1.06	0.30
C(13)	0.56	0.27	2.08	0.05	**C(55)**	0.00	0.26	0.00	1.00
C(14)	**1.06**	**0.31**	**3.38**	**0.00**	**C(56)**	-0.21	0.29	-0.73	0.47
C(15)	**0.62**	**0.34**	**1.83**	**0.08**	**C(57)**	-0.08	0.24	-0.31	0.76
C(16)	0.20	0.30	0.67	0.51	**C(58)**	0.25	0.24	1.05	0.30
C(17)	0.28	0.27	1.06	0.30	**C(59)**	-0.09	0.21	-0.43	0.67
C(18)	**-12.44**	**3.67**	**-3.39**	**0.00**	**C(60)**	**-0.49**	**0.23**	**-2.14**	**0.04**
C(19)	**-9.69**	**3.28**	**-2.95**	**0.01**	**C(61)**	0.25	0.19	1.30	0.21
C(20)	2.35	3.33	0.71	0.49	**C(62)**	-0.14	0.29	-0.50	0.62
C(21)	0.41	3.39	0.12	0.91	**C(63)**	0.13	0.31	0.42	0.68
C(22)	0.03	3.78	0.01	0.99	**C(64)**	0.24	0.28	0.84	0.41
C(23)	**6.49**	**3.20**	**2.03**	**0.05**	**C(65)**	**-0.44**	**0.24**	**-1.78**	**0.09**
C(24)	**10.25**	**3.33**	**3.08**	**0.01**	**C(66)**	**-0.43**	**0.25**	**-1.76**	**0.09**
C(25)	2.38	3.46	0.69	0.50	**C(67)**	**-0.54**	**0.28**	**-1.92**	**0.07**
C(26)	-1.10	3.66	-0.30	0.77	**C(68)**	-0.50	0.32	-1.58	0.13
C(27)	**11.81**	**3.68**	**3.21**	**0.00**	**C(69)**	-0.35	0.27	-1.32	0.20
C(28)	4.37	2.98	1.46	0.16	**C(70)**	-0.08	0.26	-0.32	0.75
C(29)	-0.69	0.76	-0.91	0.37	**C(71)**	-0.01	0.25	-0.04	0.97
C(30)	-0.71	0.91	-0.78	0.44	**C(72)**	0.02	0.18	0.11	0.91
C(31)	0.94	0.89	1.05	0.30	**C(73)**	-0.81	2.42	-0.33	0.74
C(32)	-0.36	0.64	-0.57	0.58	**C(74)**	-2.40	2.93	-0.82	0.42
C(33)	-0.45	0.64	-0.71	0.49	**C(75)**	-1.49	2.93	-0.51	0.62
C(34)	-0.76	0.69	-1.10	0.28	**C(76)**	2.48	2.39	1.04	0.31
C(35)	-0.30	0.77	-0.38	0.70	**C(77)**	0.29	2.75	0.11	0.92
C(36)	**1.61**	**0.71**	**2.27**	**0.03**	**C(78)**	-0.51	2.65	-0.19	0.85
C(37)	0.74	0.57	1.31	0.20	**C(79)**	1.19	2.45	0.49	0.63
C(38)	0.14	0.56	0.24	0.81	**C(80)**	-2.64	2.44	-1.09	0.29
C(39)	**0.95**	**0.53**	**1.79**	**0.09**	**C(81)**	-1.20	2.67	-0.45	0.66
C(40)	0.22	0.92	0.23	0.82	**C(82)**	1.03	2.81	0.37	0.72
C(41)	0.21	0.87	0.24	0.81	**C(83)**	-3.97	2.73	-1.45	0.16
C(42)	0.02	0.86	0.02	0.98	**C(84)**	-3.09	5.00	-0.62	0.54

R-squared	0.87	Mean dependent var	0.44
Adjusted R-squared	0.43	S.D. dependent var	6.88
S.E. of regression	5.18	Akaike info criterion	6.18
Sum squared resid	644.50	Schwarz criterion	8.27
Log likelihood	-249.71	Hannan-Quinn criter.	7.03
F-statistic	1.98	Durbin-Watson stat	2.42

Izvor: Izrada autora.

Prema grafikonu 16., koja prikazuje impulsni odgovor varijable burzovni indeks OSX na pozitivan naftni šok (porast cijene), može se vidjeti da povećanje cijene nafte vodi negativnom kretanju indeksa, koji svoje dno dosiže u petom razdoblju, nakon kojega se smanjuje negativan utjecaj.



Grafikon 16: Impulsni odgovor OSX indeksa na povećanje cijene nafte

Izvor: Izrada autora.

Na temelju provedene analize može se prihvatiti prva hipoteza o postojanju veze između kretanja cijene nafte i kretanja burzovnog indeksa u kratkom roku u slučaju Norveške i promatranog OSX indeksa. Također i impulsni odgovor OSX-a upućuje na potonji zaključak. U dugom roku ne prihvaća se hipoteza o postojanju veze između cijena nafte i tržišta kapitala.

3.3.8. Rusija

Rusija je uzeta analizu kao velika izvoznica nafte, ali i kao i zemlja koj se značajno razlikuje zbog svog socijalističkog nasljeđa. Prema dobivenim rezultatima, niti jedna od promatranih varijabli ne pokazuje jedinični korjen, te možemo zaključiti kako su sve varijable stacionarne na razini I(1), tablica 25. Optimalan broj pomaka iznosi 12 prema LR, FPE, AIC i HQ

informacijskim kriterijima (Tablica P1.), od kojega se prema uvjetu „p-1“ oduzima jedan pomak, te se u analizi koristi 11 pomaka.

Tablica 25: Rezultati Phillips-Perronovog testa, Rusija

Rusija - Phillips-Perron test jediničnog korjena D(X)					
Null Hipoteza: D(X) ima jedinični korjen Egzogena: Konstanta					
D(burzovni indeks - MICEX)	Adj. t-Stat	Prob.*	D(indeks potrošačkih cijena)	Adj. t-Stat	Prob.*
Phillips-Perron test statistic	-9.24	0.00	Phillips-Perron test statistic	-4.85	0.00
D(devizni tečaj)	Adj. t-Stat	Prob.*	D(indeks industrijske proizv.)	Adj. t-Stat	Prob.*
Phillips-Perron test statistic	-5.47	0.00	Phillips-Perron test statistic	-17.75	0.00
D(kratkor. kamatna stopa)	Adj. t-Stat	Prob.*	*MacKinnon (1996) one-sided p-values		
Phillips-Perron test statistic	-8.20	0.00			
Test critical values: 1% level	-3.49				
5% level	-2.89				
10% level	-2.58				

Izvor: Izrada autora.

Rezultati Grangerova testa upućuju na zaključak kako kretanje indeksa MOEX je direktno uzrokovano kretanjem varijabli indeks potrošačkih cijena i količina proizvedene nafte u svijetu, dok ostale varijable utječu neizravno, kroz utjecaj na prethodne dvije varijable (Tablica P2.). Temeljem Johansenovog testa zaključujemo kako postoji pet kointegracijskih veza (Tablica 26.).

Tablica 26: Johansenov test kointegracije, Rusija

Unrestricted Cointegration Rank Test (Trace)				
Hypothesized No. of CE(s)	**Eigenvalue**	**Trace Statistic**	**0.05 Critical value**	**Prob.** **
None *	0.82	461.95	125.62	0.00
At most 1 *	0.65	277.92	95.75	0.00
At most 2 *	0.49	163.72	69.82	0.00
At most 3 *	0.43	91.65	47.86	0.00
At most 4 *	0.18	31.49	29.80	0.03
At most 5	0.08	9.54	15.50	0.32
At most 6	0.00	0.06	3.84	0.80
Trace test indicates 5 cointegrating eqn(s) at the 0.05 level * denotes rejection of the hypothesis at the 0.05 level **MacKinnon-Haug-Michelis (1999) p-values				

Izvor: Izrada autora.

Temeljem Johansenova testa procjenjena je jednadžba oblika:

D(INDX) = C(1)*(INDX(-1) + 0.13*PO(-1) - 3.68*QO(-1) + 263.97) + C(2)*(CPI(-1) + 0.01*PO(-1) - 6.97*QO(-1) + 601.31) + C(3)*(EXR(-1) + 0.62*PO(-1) - 9.97*QO(-1) + 839.22) + C(4)*(IP(-1) - 0.13*PO(-1) - 2.22*QO(-1) + 129.62) + C(5)*(IR(-1) + 0.33*PO(-1) - 2.91*QO(-1) + 133.92) + C(6)*D(INDX(-1) + ... + C(16)*D(INDX(-11) + C(17)*D(CPI(-1) + ... + C(27)*D(CPI(-11) + C(28)*D(EXR(-1) + ... + C(38)*D(EXR(-11) + C(39)*D(IP(-1) + ... + C(49)*D(IP(-11) + C(50)*D(IR(-1) + ... + C(60)*D(IR(-11) + C(61)*D(PO(-1) + ... + C(71)*D(QO(-11) + C(72)*D(PO(-1) + ... + C(82)*D(QO(-11) + C(83)., (15.)

te na temelju procijenjenih koefcijenata (Tablica 27.) koji su statistički značajni glasi:

D(INDX) = 0.73*D(INDX(-8)) + 0.33*D(IR(-7)) + 0.50*D(PO(-1))., (16.)

gdje se oznaka INDX odnosi na index MOEX, CPI na indeks potrošačkih cijena, EXR na tečaj eura, IP na industrijsku proizvodnju, IR na kratkoročnu kamatnu stopu, PO na cijenu, a QO količinu nafte. Procjenjeni koeficijenti jednadžbe nalaze se u tablici 27., te su statistički značajni koeficijenti podebljani. Granica statističke značajnosti je 10%, odnosno 0,10.

Provođenjem VECM analize, izračunat rezultat je statistički značajan u kratkom roku, te temeljem rezultata zaključujemo da kretanje MOEX indeksa ovisi o kratkoročnim kamatnim stopama i cijeni nafte u kratkom roku (Tablica 27.).

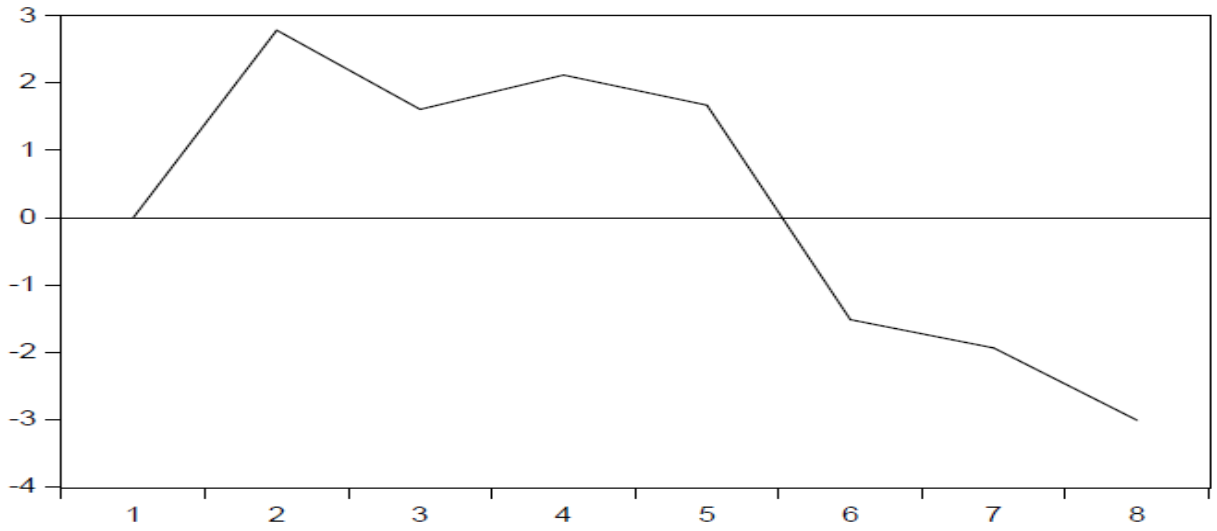
Na grafikonu 17. vidi se impulsni odgovor MOEX indeksa na naftni šok, povećanje cijene nafte. Na temelju impulsnog odgovora vidi se da u prvih pet razdoblja sa rastom cijene raste i vrijednost indeksa, dok u daljnjim razdobljima utjecaj postaje negativan.

Tablica 27: VECM procijenjen metodom najmanjih kvadrata, Rusija

	Koeficijent	St. Greška	t-Statistic	Prob.		Koeficijent	St. Greška	t-Statistic	Prob.
C(1)	-1.45	1.01	-1.44	0.16	**C(43)**	-0.99	1.55	-0.64	0.53
C(2)	-0.98	0.91	-1.08	0.29	**C(44)**	-0.65	1.35	-0.48	0.63
C(3)	1.01	0.83	1.22	0.24	**C(45)**	-0.73	1.17	-0.63	0.54
C(4)	2.23	2.93	0.76	0.45	**C(46)**	-0.84	0.88	-0.95	0.35
C(5)	-0.31	0.22	-1.39	0.18	**C(47)**	-0.91	0.67	-1.37	0.18
C(6)	0.95	0.98	0.97	0.34	**C(48)**	-0.67	0.47	-1.44	0.16
C(7)	0.46	0.93	0.49	0.63	**C(49)**	-0.38	0.26	-1.47	0.15
C(8)	0.87	0.84	1.03	0.31	**C(50)**	0.25	0.23	1.07	0.30
C(9)	0.33	0.65	0.51	0.62	**C(51)**	0.18	0.22	0.80	0.43
C(10)	0.64	0.70	0.90	0.38	**C(52)**	0.29	0.23	1.29	0.21
C(11)	0.48	0.54	0.88	0.38	**C(53)**	0.18	0.22	0.81	0.43
C(12)	0.63	0.49	1.28	0.21	**C(54)**	0.36	0.24	1.48	0.15
C(13)	**0.73**	**0.39**	**1.85**	**0.08**	**C(55)**	0.17	0.19	0.87	0.39
C(14)	0.62	0.41	1.52	0.14	**C(56)**	**0.33**	**0.20**	**1.68**	**0.10**
C(15)	0.41	0.28	1.45	0.16	**C(57)**	0.06	0.15	0.40	0.69
C(16)	0.20	0.25	0.82	0.42	**C(58)**	0.21	0.15	1.35	0.19
C(17)	4.62	4.85	0.95	0.35	**C(59)**	0.06	0.10	0.58	0.56
C(18)	-1.38	4.24	-0.33	0.75	**C(60)**	0.09	0.10	0.99	0.33
C(19)	-0.99	4.49	-0.22	0.83	**C(61)**	**0.50**	**0.25**	**2.01**	**0.06**
C(20)	0.67	4.57	0.15	0.89	**C(62)**	0.13	0.28	0.48	0.64
C(21)	-0.60	4.52	-0.13	0.90	**C(63)**	0.35	0.33	1.07	0.29
C(22)	1.84	4.41	0.42	0.68	**C(64)**	0.07	0.30	0.23	0.82
C(23)	4.35	4.32	1.01	0.32	**C(65)**	0.17	0.30	0.56	0.58
C(24)	-3.95	3.96	-1.00	0.33	**C(66)**	-0.14	0.34	-0.40	0.69
C(25)	-2.01	3.90	-0.52	0.61	**C(67)**	0.24	0.34	0.71	0.49
C(26)	1.59	3.66	0.43	0.67	**C(68)**	-0.06	0.27	-0.22	0.83
C(27)	0.32	2.94	0.11	0.91	**C(69)**	0.00	0.30	0.00	1.00
C(28)	-0.48	0.70	-0.69	0.49	**C(70)**	-0.10	0.34	-0.30	0.77
C(29)	-0.73	0.66	-1.10	0.28	**C(71)**	0.22	0.30	0.75	0.46
C(30)	-0.30	0.59	-0.51	0.61	**C(72)**	2.87	6.96	0.41	0.68
C(31)	-0.57	0.56	-1.02	0.32	**C(73)**	2.62	6.50	0.40	0.69
C(32)	-0.52	0.43	-1.20	0.24	**C(74)**	2.12	6.32	0.34	0.74
C(33)	-0.40	0.48	-0.84	0.41	**C(75)**	-0.78	6.63	-0.12	0.91
C(34)	-0.11	0.48	-0.23	0.82	**C(76)**	2.43	6.82	0.36	0.72
C(35)	-0.17	0.47	-0.36	0.72	**C(77)**	1.60	5.78	0.28	0.78
C(36)	-0.35	0.34	-1.03	0.31	**C(78)**	4.05	4.93	0.82	0.42
C(37)	0.18	0.36	0.52	0.61	**C(79)**	1.75	4.23	0.41	0.68
C(38)	0.04	0.31	0.13	0.90	**C(80)**	1.04	3.65	0.29	0.78
C(39)	-1.99	2.79	-0.71	0.48	**C(81)**	-4.05	3.24	-1.25	0.22
C(40)	-1.55	2.50	-0.62	0.54	**C(82)**	-0.85	2.98	-0.28	0.78
C(41)	-1.45	2.23	-0.65	0.52	**C(83)**	-0.98	12.04	-0.08	0.94
C(42)	-1.10	1.88	-0.58	0.56					

R-squared	0.80	Mean dependent var	0.22
Adjusted R-squared	0.12	S.D. dependent var	7.28
S.E. of regression	6.82	Akaike info criterion	6.75
Sum squared resid	1165.17	Schwarz criterion	8.82
Log likelihood	-281.68	Hannan-Quinn criter.	7.59
F-statistic	1.18	Durbin-Watson stat	2.05

Izvor: Izrada autora.



Grafikon 17: Impulsni odgovor MOEX indeksa na povećanje cijene nafte

Izvor: Izrada autora.

Nakon provedene analize, u slučaju MOEX indeksa, prihvaćamo prvu hipotezu koja tvrdi da postoji veza između cijene nafte i tržišta kapitala, samo za kratki rok u Rusiji. U dugom roku odbacuje se prva hipoteza. Daljnja razrada druge hipoteze za Rusiju, kao i za ostale zemlje biti će prikazana u dijelu „3.4. Rasprava istraživanja“.

3.4. RASPRAVA ISTRAŽIVANJA

Temeljem provedene analize došlo se do određenih zaključaka na temelju kojih se mogu potvrditi ili odbaciti hipoteze postavljene u ovom radu. Pri prihvaćanju ili odbacivanju hipoteza držati ćemo se načela koja su prethodno postavljena u radu.

Varijabla indeks potrošačkih cijena, u kratkom roku, na temelju provedene analize u sedam od osam zemalja utječe na kretenje varijable burzovni indeks (DAX, CAC40, ATX, SBITOP, FTSE MIB, CROBEX i OSX), dok ne utječe u slučaju Rusije (MOEX). U dugom roku navedena varijabla utječe samo na kretanje austrijskog ATX indeksa.

Varijabla deviznog tečaja domaće valute prema dolaru u kratkom roku utječe na kretanje svih indeksa osim CAC40 i MOEX-a, dok utjecaj u dugom roku je vidljiv na indekse CAC40, ATX,

FTSE MIB i CROBEX. Indeks industrijske proizvodnje u kratkom roku utječe na CAC 40, ATX i FTSE MIB, dok utjecaj navedene varijable ne postoji u dugom roku na nijedan burzovni indeks.

Kratkoročne kamatne stope u analizi kratkog roka utječu na sve indekse, dok je utjecaj u dugom roku vidljiv na CAC40, ATX i FTSE MIB indeks.

Količina nafte na svjetskom tržištu u dugom roku utječe na kretanje svih burzovnih indeksa, izuzev slovenskog SBITOP-a i ruskog MOEX-a. U kratkom roku navedena varijabla nema utjecaja na CROBEX, OSX i MICEX dok u drugim slučajevima utjecaj je vidljiv.

Promatrana varijabla cijena nafte u kratkom roku utječe na sedam indeksa (DAX, ATX, SBITOP, FTSE MIB, CROBEX, OSX i MOEX), te u dugom roku na indekse DAX, ATX, FTSE MIB i CROBEX.

Prema prethodno opisanome možemo prihvatiti prvu hipotezu, u kratkom roku, koja glasi: "Promjena cijena nafte utječe na na tržišta kapitala", te zaključujemo kako su rezultati ovog istraživanja u skladu sa relevantnom ekonomskom literaturom navedenom kroz rad (Alikhanov i Nguyen, 2011. Killan i Park, 2009., Guesmi et al., 2016., Ogiri et al., 2013., Zhou i Wang, 2013., i drugi), te da je utjecaj cijena nafte prisutan u kratkom roku u većini promatranih zemalja (izuzev francuskog CAC40 indeksa), odnosno cijena nafte utječe na reprezentativni indeks većine zemalja, neovisno jesu li zemlje neto uvoznice ili neto izvoznice nafte. U dugom roku prva hipoteza se ne prihvaća u slučaju zemalja neto izvoznica nafte. Prvu hipotezu prihvaćamo, u dugom roku, za zemlje neto uvoznice jer je utjecaj nafte značajan u četiri od šest slučajeva zemalja neto uvoznica.

Druga istraživčka hipoteza glasi "Utjecaj promjena cijena nafte razlikuje se kod zemlja uvoznica od zemalja izvoznica". Temeljem provedene analize, vidimo da se prema jačini, veličini koeficijenta, utjecaj varijable i u zemljama uvoznicama i zemljama izvoznicama u bitnome ne razlikuje. U slučaju Njemačke, Francuske, Austrije i Italije vidi se kako povećanje cijene nafte utječe negativno na kretanje burzovnih indeksa (Grafikoni 10., 11, 12. i 15.). Od zemlja uvoznica nafte jedina zemlja koja pokazuje pozitivan utjecaj je Slovenija (Grafikon 13.). Hrvatski CROBEX pokazuje mješovite rezultate, te je utjecaj na indeks inicijalno pozitivan, te prelazi u negativan u petom razdoblju, te nastavlja negativno djelovati (Grafikon 14.). U slučaju zemalja

neto izvoznica utjecaj je različit u obje zemlje. Povećanje cijene nafte u slučaju Norveške djeluje negativno na kretanje burzovnog indeksa (Grafikon 16.), dok u slučaju Rusije odgovor je prvo pozitivan, pa negativan nakon petog razdoblja (Grafikon 17.). Drugu istraživačku hipotezu se odbacuje, jer je odgovor na pozitivan naftni šok (povećanje cijene) dominantno negativan u svim zemljama, te se temeljem VECM analize i impulsnih odgovora ne može izvesti potvrditi navedena hipoteza. Navedeni zaključak nije iznenađujući za zemlje neto uvoznice, koliko za neto izvoznice, ipak rezultatse može objasniti povećanjem cijena inputa u proizvodnji dobara i usluga čemu vodi rast cijene nafte, odnosno energenata. Ključ ovakvoga ponašanja i reakcije burzovnih indeksa na povećanje cijene nafte leži u većim troškovima s kojima se kompanije susreću u svom poslovanju koji je posljedica porasta cijene nafte, odnosno možemo agregirati zaključak na sve energente i/ili inpute, te porast troškova poslovanja.

4. ZAKLJUČAK

Svrha i cilj ovog istraživanja bilo je istraživanje veze između cijena nafte i kretanja burzovnih indeksa analizirajući izabrane zemlje. U analizi se pokušalo odrediti utjecaj cijena nafte, kratkoročnih kamatnih stopa, deviznog tečaja prema dolaru, indeksa potrošačkih cijena, industrijske proizvodnje i količine proizvedene nafte na izabrane burzovne indekse.

Kako bi se došlo do rezultata, prvo se testiralo postojanje trenda u varijablama pri levelu, prvoj i drugoj diferenciji, te se utvrdilo kako su sve varijable stacionarne na prvoj diferenciji koju se koristilo pri modeliranju. Također smo provela se preliminarna VAR analiza kako bi se odredio optimalan broj pomaka, te test Grangerove kauzalnosti. Zatim se proveo Johansenov test kointegracije, čije su se kointegracijske jednadžbe testirale kako bi se dobili rezultati analize.

Pomoću analize vremenskih nizova, korištenjem "Vector error correction model" metode došli smo do zaključaka. Prihvatila se prva hipoteza da cijene nafte utječu, za zemlje neto uvoznice i zemlje neto izvoznice nafte, na burzovne indekse u kratkom roku, dok je u dugom roku prva hipoteza odbačena u slučaju zemalja neto izvoznica. Druga hipoteza se odbacila jer rezultati pokazuju kako je utjecaj cijena nafte na burzovne indekse uglavnom negativan neovisno o tome je li zemlja uvoznica ili izvoznica nafte, temeljem rezultata VECM analize i impulsnih odgovora, te se kao moguće objašnjenje ovakvog nalaza krije u većim troškovima s kojima se kompanije sreću pri rastu cijene energenata.

Rezultati ovog rada mogu poslužiti kao orjentir potencijalnim sudionicima na financijskim tržištima u određivanju karaktera utjecaja cijena nafte i promatranih varijabli na kretanje pojedinih burzovnih indeksa. Analizirajući promatrani problem došlo se do bitnih saznanja o prirodi promatrane veze, no ta veza nije nipošto u potpunosti određena. Daljnja istraživanja u ovom području također mogu dodatno pridonijeti analizi problema, pimjerice jedan od daljnjih pristupa bi mogao biti "wawelet" analiza koja daje dovoljno slobode istraživaču u odnosu na parametrijske testove.

LITERATURA

1. Ahmadi, M., Manera, M., Sadeghzadeh, M. (2016.): Global oil market and the U.S. stock returns. Energy, 114, str. 1277-1287.
2. Ahmed, R., A., Naser, H. (2016): Oil price shocks and stock market performance in emerging economies: some evidence using FAVAR models, Munich Personal RePEc Archive.
3. Alikhanov, A., Nguyen, T. (2011.): The impact of oil price on stock returns in oil-exporting economies: The case of Russia and Norway, LUND University.
4. Anand, B., Paul, S., Ramachandran, M. (2014): Volatility between oil and stock market returns, Indian Economic Review, 49 (1), str. 37-56.
5. Antonakis, N., Chatziantoniou, Filis, G. (2017.): Oil shocks and stock markets Dynamic connectedness under the prism of recent geopolitical and economic unrest, International rewiew of Financial Analysis, 50, str. 1-26.
6. Aydogan, B., Tunc, G., Yelkenci, T. (2017.): The impact of oil price volatility on net-oil exporter and importer countries'stock markets, Euroasian Economic Review, 7 (2), str. 231-253.
7. Apergis, N., Miller, M., S. (2009 .): Do structural oil-market shocks affect stock prices?, Energy Economics, 31, str. 569-575.
8. Arouri, E., H., M., Foulquier, P., Fouquau, J. (2011.): Oil prices and stock markets in Europe: A sector perspective, Louvain Economic Review, 77 (1), str. 5-30.
9. Bashar, A., Z. (2006.): Wild oil prices, but brave stock markets! The case of GCC stock markets, Operational Research, 6 (2), str. 145-162.
10. Basher, S., A., Sadorsky, P. (2006.): Oil price risk and emerging stock markets, Global Finance Journal, 17., str. 224-251.
11. Bams, D., et. al., D. (2017.): Does oil and gold price uncertainty matter for the stock market?, Journal of Empirical Finance, 44, str. 270-285.
12. Bastianin, A., Conti, F., Manera, M. (2016.): The impact of oil price shocks on stock market volatility: Evidence from the G7 countries, Energy Policy, 98, str. 160-169.
13. Bečka burza (2018.) Bečka burza, [Internet], raspoloživo na: https://www.wienerborse.at/en/, pristupljeno na datum 10.04.2018.

14. Brose Olsen, A., Henriz, P. (2014.): Oil Price Shocks and Stock Market Returns, LUND University.
15. Burza u Ljubljani (2018.) Burza u Ljubljani, [Internet], raspoloživo na: http://www.ljse.si/cgi-bin/jve.cgi?doc=1468, pristupljeno na datum 10.04.2018.
16. Burza u Oslu (2018.) Burza u Oslu, [Internet], raspoloživo na: https://www.oslobors.no/ob_eng/, pristupljeno na datum 10.04.2018.
17. Canedo, Donoso, D., I. (2009.): Oil price shocks and stock markets, Institute for Advanced Development Studies.
18. Degiannakis, S., Filis, G., Floros, C. (2011.): Dynamic correlation between stock market and oil prices: The case of oil-importing and oil-exporting countries,International Review of Financial Analysis, 20 (3), str. 152-164..
19. Dhaoui, A., Kharief, N. (2014). Empirical Linkage between Oil Price and Stock Market Returns and Volatility: Evidence from International Developed Markets. Economics Discussion Papers, Kiel Institute for the World Economy, 12.
20. EC (2018.) Neto uvoz primarne energije, [Internet], raspoloživo na: http://ec.europa.eu/eurostat/statisticsexplained/images/e/e5/Net_imports_of_primary_energy%2C_2005-2015_YB17, pristupljeno na datum 30.03.2018.
21. EC (2018.) Zavisnost o uvozu nafte, [Internet], raspoloživo na: http://ec.europa.eu/eurostat/statistics-explained/images/8/87/Oil_import_dependency%2C_1990-2015%2C_percentage_update.png, pristupljeno na datum 30.03.2018.
22. ECB (2018.) Short term interest rate (Croatia), [Internet], raspoloživo na: http://sdw.ecb.europa.eu/browseSelection.do?df=true&ec=&dc=&oc=&pb=&rc=&DATASET=1&DATASET=2&DATASET=3&DATASET=4&DATASET=5&DATASET=6&removeItem=&removedItemList=&mergeFilter=&activeTab=&showHide=&node=bbn72&legendRef=reference, pristupljeno na datum 20.03.2018.
23. EURONEXT (2018.) Euronext, [Internet], raspoloživo na: https://www.euronext.com/en/, pristupljeno na datum 10.04.2018.
24. Frankfurtska burza (2018.) Frankfurtska burza, [Internet], raspoloživo na: http://en.boerse-frankfurt.de/, pristupljeno na datum 10.04.2018.

25. Gay, D., R. (2016.): Effect Of Macroeconomic Variables On Stock Market- Returns For Four Emerging Economies: Brazil, Russia, India, And China, International Business & Economics Research Journal, 15 (3), str 119-125.
26. Guesmi, K., Boubaker, H., Lai, V., S. (2016.): From oil to stock markets, Journal of Economic Integration, 31 (1), str. 103-133.
27. Hamilton, J., D. (1983.): Oil and the Macroeconomy since Worrld War II, The Journal of Political Economy, 91 (2), str. 228-248.
28. INVESTING.COM (2018.) Burzovni indeksi, [Internet], raspoloživo na: https://www.investing.com/indices/world-indices, pristupljeno na datum 05.03.2018.
29. Jones, C., M., Kaul, G. (1996.): Oil and stock markets, The Journal of Finance, 51 (2), str. 463-491.
30. Killan, L., Park, C. (2009.): The impact of oil price shocks on the U.S. stock market, Internationa Economic Review, 50 (4), str. 1267-1287.
31. Mohanty, S., K., Akhigbe, A., Al-Khyal, T., A., Bugshan, T. (2013.): Oil and stock market activity when prices go u and down: the case of the oil and gas industry, Review of Quantitative Finance and Accounting, 41 (2), str. 253-272.
32. Meuller, E., C. (2009.): Oil and its impact on economics and financial markets. University of St.Gallen.
33. Međunarodni monetarini fond (2017.): International financial statistics na dan 27.03.2017. godine. [Internet], raspoloživo na: https://data.world/imf/international-financial-statis, pristupljeno na datum 20.03.2018.
34. Međunarodni monetarini fond (2017.): IMF DATA, veljača 2018. godine. [Internet], raspoloživo na: http://data.imf.org/regular.aspx?key=61545854, pristupljeno na datum 20.03.2018.
35. Moskovska burza (2018.) Moskovska burza, [Internet], raspoloživo na: https://www.moex.com/en/, pristupljeno na datum 10.04.2018.
36. Ogiri, H., I., Uddin, M., M., Dubon, P. (2013.): Oil price & stock market performance in Nigeria: An empirical analysis, American Journal of Social and Management Sciences, 4 (1), str. 20-41.
37. OECD (2018.) Short term interest rate, [Internet], raspoloživo na: http://stats.oecd.org/Index.aspx?QueryId=51659#, pristupljeno na datum 20.03.2018.

38. Park, W., J., Ratti, A., R. (2007.): Oil price shocks and stock markets in the U.S. and 13 european countries, Energy Economics, 30 (5), str. 2587-2608.
39. Pinho, C., Madaleno, M. (2016.): Oil prices and stock returns: nonlinear links across sectors, Portugese Economic Journal, 15 (2), str. 79-97.
40. Sadorsky, P. (2001.): Risk factors in stock returns of Canadian oil and gas companies, Energy Economics, 23 (1), str.17–28.
41. Salisu, A., A., Isah, K., O. (2017.): Revisiting the oil price and stock market nexus: A nonlinear Panel ARDL approach, Economic Modelling, 66, str. 258-271.
42. Siddiqui, M.,M. (2014.): Oil price fluctuation and stock market performance-the case of Pakistan, Journal of International Business and Economics, 2 (1), str 47-53.
43. Shafaai, B., S., Masih, M. (2013.): Stock market and crude oil relationship: A wavelet analysis, Munich Personal RePEc Archive.
44. Smith, J., L. (2009.): World oil: market or mayhem?, The Journal of Economic Perspectives, 23 (3), str. 145-164.
45. Talijanska burza (2018.) Talijanska burza, [Internet], raspoloživo na: http://www.borsaitaliana.it/homepage/homepage.en.htm, pristupljeno na datum 10.04.2018.
46. U.S.: Energy Information Agency (2018.) BRENT cijene nafte, [Internet], raspoloživo na: https://www.eia.gov/dnav/pet/ hist/ LeafHandler.ashx?n=PET&s =rbrte&f=M., pristupljeno na datum 20.03.2018.
47. U.S.: Energy Information Agency (2018.) O energiji, [Internet], raspoloživo na: https://www.eia.gov/todayinenergy/detail.php?id=33732, pristupljeno na datum 20.03.2018.
48. U.S.: Energy Information Agency (2018.) Proizvodnja sirove nafte, [Internet], raspoloživo na: https://www.eia.gov/beta/international/data/browser/#/?pa=0000000000000000000000000000000003&f=M&c=00000000000000000000000000000000000000000000000001&tl_type=a&tl_id=1-M&vs=INTL.57-1-WORL-TBPD.M&vo=0&v=T&start=200507&end=201711, pristupljeno na datum 20.03.2018.
49. Wang, Y., Wu, C., Yang, L. (2013.): Oil price shocks and stock market activities: Evidence from oil-importing and oil-exporting countries, Journal of Comparative economics, 41, str. 1220-1239.
50. Wei, Y., Guo, X. (2017.): Oil price shocks and China's stock market, Energy, 140 (1), str 185-197.

51. Zagrebačka burza (2018.) Zagrebačka burza, [Internet], raspoloživo na: http://www.zse.hr/, pristupljeno na datum 10.04.2018.
52. Zhou, S., Wang, D. (2012.): The macroeconomic and financial effects of oil price shocks, Munich Personal RePEc Archive.

POPIS GRAFIKONA:

GRAFIKON 1: OSCILACIJE CIJENE NAFTE 1987.-2016. (GODIŠNJE) 9
GRAFIKON 2: KRETANJE DAX INDEKSA 2007.-2016. GODINE 29
GRAFIKON 3: KRETANJE CAC40 INDEKSA 2007.-2016. GODINE 30
GRAFIKON 4: KRETANJE ATX INDEKSA 2007.-2016. GODINE 31
GRAFIKON 5: KRETANJE FTSE-MIB INDEKSA 2007.-2016. GODINE 32
GRAFIKON 6: KRETANJE SBITOP INDEKSA 2007.-2016. GODINE 33
GRAFIKON 7: KRETANJE OBX INDEKSA 2007.-2016. GODINE 33
GRAFIKON 8: KRETANJE MOEX INDEKSA 2007.-2016. GODINE 34
GRAFIKON 9: KRETANJE CROBEX INDEKSA 2007.-2016. GODINE 35
GRAFIKON 10: IMPULSNI ODGOVOR DAX INDEKSA NA POVEČANJE CIJENE NAFTE 42
GRAFIKON 11: IMPULSNI ODGOVOR CAC40 INDEKSA NA POVEĆANJE CIJENE NAFTE 46
GRAFIKON 12: IMPULSNI ODGOVOR ATX INDEKSA NA POVEĆANJE CIJENE NAFTE 50
GRAFIKON 13: IMPULSNI ODGOVOR SBITOP INDEKSA NA POVEĆANJE CIJENE NAFTE 54
GRAFIKON 14: IMPULSNI ODGOVOR CROBEX INDEKSA NA POVEĆANJE CIJENE NAFTE 58
GRAFIKON 15: IMPULSNI ODGOVOR FTSE MIB INDEKSA NA POVEĆANJE CIJENE NAFTE 62
GRAFIKON 16: IMPULSNI ODGOVOR OSX INDEKSA NA POVEĆANJE CIJENE NAFTE 66
GRAFIKON 17: IMPULSNI ODGOVOR MOEX INDEKSA NA POVEĆANJE CIJENE NAFTE 70

POPIS SLIKA:

SLIKA 1: CIJENA NAFTE I RECESIJE U SAD-U 12
SLIKA 2: FAZE I FAZNA RAZLIKA NAFTNIH POVRATA I POVRATA NA TRŽIŠTU KAPITALA 14
SLIKA 3: TEST GRANGEROVE KAUZALNOSTI 16
SLIKA 4: WAVELET -S&P500 KRETANJE SA CIJENOM NAFTE 17
SLIKA 5: IMPULSNI ODGOVOR BURZOVNOG INDEKSA I OSTALIH VARIJABLI NA NAFTNI ŠOK, RUSIJA 18
SLIKA 6: IMPULSNI ODGOVOR IZABRANIH INDUSTRIJA NA NAFTNI ŠOK PONUDE 19
SLIKA 7: IMPULSNI ODGOVOR IZABRANIH INDUSTRIJA NA NAFTNI ŠOK POTRAŽNJE 19
SLIKA 8: IMPULSNI ODGOVOR IZABRANIH INDUSTRIJA NA NAFTNI ŠOK ŠPEKULATIVNE POTRAŽNJE 20
SLIKA 9: IMPULSNI ODGOVOR IZABRANIH INDUSTRIJA NA NAFTNE ŠOKOVE, KINA 21
SLIKA 10: VREMENSKI ZAVISNA KORELACIJA IZMEĐU NJEMAČKOG DAX INDEKSA I CIJENA NAFTE 22
SLIKA 11: NETO IZVOZ NAFTE IZ RUSIJE U 2016. GODINI 28

POPIS TABLICA:

TABLICA 1: 20 NAJVEĆIH SVJETSKIH NAFTNIH KOMPANIJA U 2007. GODINI... 10
TABLICA 2: NETO UVOZ PRIMARNIH OBLIKA ENERGIJE, EKVIVALENT TISUĆAMA TONA NAFTE, 2005.-2015. 25
TABLICA 3: NETO UVOZ NAFTE 1990.-2015. 27
TABLICA 4: REZULTATI PHILLIPS-PERRONOVOG TESTA, NJEMAČKA 38
TABLICA 5: JOHANSENOV TEST, NJEMAČKA 39
TABLICA 6: VECM PROCJENA METODOM NAJMANJIH KVADRATA, NJEMAČKA 41
TABLICA 7: REZULTATI PHILLIPS-PERRONOVOG TESTA, FRANCUSKA 43
TABLICA 8: JOHANSENOV TEST, FRANCUSKA 43
TABLICA 9: VECM PROCIJENJEN METODOM NAJMANJIH KVADRATA, FRANCUSKA 45
TABLICA 10: REZULTATI PHILLIPS-PERRONOVOG TESTA, AUSTRIJA 47
TABLICA 11: JOHANSENOV TEST KOINTEGRACIJE, AUSTRIJA 47
TABLICA 12: VECM PROCIJENJEN METODOM NAJMANJIH KVADRATA, AUSTRIJA 49
TABLICA 13: REZULTATI PHILLIPS-PERRONOVOG TESTA, SLOVENIJA 51
TABLICA 14: JOHANSENOV TEST, SLOVENIJA 51
TABLICA 15: VECM PROCIJENJEN METODOM NAJMANJIH KVADRATA, SLOVENIJA 53
TABLICA 16: REZULTATI PHILLIPS-PERRONOVOG TESTA, HRVATSKA 55
TABLICA 17: JOHANSENOV TEST, HRVATSKA 55
TABLICA 18: VECM PROCIJENJEN METODOM NAJMANJIH KVADRATA, HRVATSKA..... 57
TABLICA 19: REZULTATI PHILLIPS-PERRONOVOG TESTA, ITALIJA 59
TABLICA 20: JOHANSENOV TEST, ITALIJA..... 59
TABLICA 21: VECM PROCIJENJEN METODOM NAJMANJIH KVADRATA, ITALIJA 61
TABLICA 22: REZULTATI PHILLIPS-PERRONOVOG TESTA, NORVEŠKA 63

TABLICA 23: JOHANSENOV TEST KOINTEGRACIJE, NORVEŠKA 63
TABLICA 24: VECM PROCIJENJEN METODOM NAJMANJIH KVADRATA, NORVEŠKA..... 65
TABLICA 25: REZULTATI PHILLIPS-PERRONOVOG TESTA, RUSIJA..... 67
TABLICA 26: JOHANSENOV TEST KOINTEGRACIJE, RUSIJA 67
TABLICA 27: VECM PROCIJENJEN METODOM NAJMANJIH KVADRATA, RUSIJA 69

PRILOZI:

Tablica P1.: Optimalna dužina pomaka, sve zemlje

VAR kriterij za odabir pomaka (eng. "lag")

Endogene varijable: burzovni indeksi, indeks potrošačih cijena, devizni tečaj prema dolaru, indeks industrijske proizvodnje, kratkoročne kamatne stope, cijena nafte, količina nafte

Egzogene varijable: C

Uzorak: 2007M01 2016M12

Uključeno observacija: 108

	Njemačka						Francuska					
Lag	LogL	LR	FPE	AIC	SC	HQ	LogL	LR	FPE	AIC	SC	HQ
0	-2786.76	NA	6.94E+13	51.74	51.91	51.81	-2762.44	NA	4.42E+13	51.29	51.46	51.36
1	-1939.97	1568.13	26670754	36.96	38.35*	37.53	-1926.01	1548.93	20598247	36.70	38.10*	37.27
2	-1856.49	143.77	14236985	36.32	38.93	37.38*	-1820.62	181.51	7327438	35.66	38.27	36.72
3	-1806.57	79.51	14390682	36.31	40.13	37.86	-1785.27	56.30	9700730	35.91	39.74	37.46
4	-1765.98	59.38	17748825	36.46	41.50	38.51	-1727.63	84.33	8725093	35.75	40.79	37.80
5	-1699.03	89.26	13941070	36.13	42.39	38.67	-1647.08	107.40	5327120	35.17	41.43	37.71
6	-1641.68	69.03	13750125	35.98	43.45	39.01	-1582.42	77.83	4588936	34.88	42.35	37.91
7	-1593.44	51.81	17160347	35.99	44.68	39.51	-1516.06	71.27	4094455	34.56	43.25	38.08
8	-1549.83	41.19	25500507	36.09	46.00	40.11	-1453.66	58.93	4296829	34.31	44.22	38.33
9	-1477.25	59.14	25003469	35.65	46.78	40.16	-1400.79	43.09	6067562	34.24	45.36	38.75
10	-1393.06	57.69	23384304	35.00	47.34	40.01	-1305.57	65.24	4626957	33.38	45.72	38.39

11	-1305.38	48.71	26178444	34.28	47.84	39.78	-1205.65	55.51	4128921	32.44	46.00	37.94
12	-1102.86	**86.26***	**5118994.***	**31.44***	46.22	37.43	-1027.74	**75.77741***	**1273632.***	**30.05***	44.83	**36.04***
	Austrija						**Slovenija**					
Lag	LogL	LR	FPE	AIC	SC	HQ	LogL	LR	FPE	AIC	SC	HQ
0	-2841.88	NA	1.93E+14	52.76	52.93	52.83	-2863.68	NA	2.88E+14	53.16	53.33	53.23
1	-1923.67	1700.38	19723454	36.66	38.05*	37.22	-1959.47	1674.47	38270480	37.32	38.71*	37.89
2	-1852.43	122.69	13206156	36.25	38.86	37.31	-1859.26	172.58	14985700	36.38	38.98	37.43
3	-1817.50	55.63	17619990	36.51	40.33	38.06	-1812.19	74.96	15969247	36.41	40.24	37.96
4	-1760.43	83.49	16016713	36.36	41.40	38.40	-1756.54	81.40	14904555	36.29	41.33	38.33
5	-1666.42	125.35	7621152	35.53	41.78	38.06	-1702.10	72.59	14757179	36.19	42.45	38.72
6	-1602.83	76.54	6696236	35.26	42.73	38.29	-1658.04	53.03	18616385	36.28	43.75	39.31
7	-1540.02	67.46	6380672	35.00	43.69	38.52	-1589.16	73.98	15851460	35.91	44.60	39.43
8	-1459.99	75.58	4830744	34.43	44.33	38.44	-1505.78	78.75	11278987	35.27	45.18	39.29
9	-1395.02	52.94	5452578	34.13	45.26	38.64	-1451.63	44.12	15557264	35.18	46.30	39.69
10	-1287.99	73.33	3341100	33.06	45.40	38.06	-1345.52	72.70	9695838	34.12	46.46	39.13
11	-1178.80	60.66	2511543	31.94	45.50	37.44	-1181.10	91.35	2620415	31.98	45.54	37.48
12	-925.17	**108.03***	**190599.0***	**28.15***	42.93	**34.14***	-1020.41	**68.44***	**1112110.***	**29.92***	44.69	**35.91***
	Hrvatska						**Italija**					
Lag	LogL	LR	FPE	AIC	SC	HQ	LogL	LR	FPE	AIC	SC	HQ
0	-2777.26	NA	5.82E+13	51.56	51.73	51.63	-2876.35	NA	3.65E+14	53.40	53.57	53.47
1	-1965.77	1502.	43006882	37.44	38.83*	38.00	-	1770.92	18447110	36.59	37.98	37.16

		77					1920.06				*	
2	-1871.00	163.20	18627945	36.59	39.20	37.65*	-1837.31	142.50	9981996	35.97	38.58	37.03
3	-1827.46	69.34	21191335	36.69	40.52	38.24	-1778.04	94.40	8485625	35.78	39.60	37.33
4	-1781.82	66.78	23799639	36.76	41.80	38.80	-1736.25	61.13	10236312	35.91	40.95	37.96
5	-1726.54	73.70	23205951	36.64	42.90	39.18	-1686.94	65.75	11145296	35.91	42.16	38.44
6	-1655.83	85.12	17870502	36.24	43.71	39.27	-1638.43	58.39	12947844	35.92	43.39	38.95
7	-1581.12	80.25*	13658489	35.76	44.45	39.29	-1576.24	66.80	12478355	35.67	44.36	39.20
8	-1530.46	47.84	17815380	35.73	45.64	39.75	-1521.34	51.85	15045285	35.56	45.47	39.58
9	-1452.78	63.29	15892798	35.20	46.33	39.71	-1450.83	57.45	15329598	35.16	46.29	39.67
10	-1370.51	56.37	15401753	34.58	46.93	39.59	-1376.43	50.98	17184703	34.69	47.04	39.70
11	-1258.51	62.22	10990135	33.42	46.98	38.91	-1183.16	107.37	2722755	32.02	45.58	37.52
12	-1124.21	57.20	**7602594.***	**31.84***	46.61	37.83	-953.42	**97.85***	**321649.7***	**28.68***	43.45	**34.67***

	Norveška						**Rusija**					
Lag	LogL	LR	FPE	AIC	SC	HQ	LogL	LR	FPE	AIC	SC	HQ
0	-2621.35	NA	3.24E+12	48.67	48.85	48.74	-2936.52	NA	1.11E+15	54.51	54.68	54.58
1	-1786.36	1546.28	1551234.00	34.12	35.5085*	34.68	-2080.35	1585.51	3.59E+08	39.56	40.95*	40.13
2	-1690.77	164.63	661627.40	33.25	35.86	34.31	-1970.90	188.50	1.18E+08	38.44	41.05	39.50
3	-1640.67	79.79	666569.50	33.23	37.06	34.79	-1924.49	73.90	1.28E+08	38.49	42.32	40.04
4	-1591.80	71.50	705246.10	33.24	38.28	35.28	-1890.31	50.01	1.77E+08	38.76	43.81	40.81
5	-1546.71	60.12	830396.70	33.31	39.57	35.85	-1834.15	74.88	1.70E+08	38.63	44.89	41.17
6	-1491.89	65.98	858325.70	33.20	40.68	36.23	-	48.96	2.29E+08	38.79	46.26	41.82

							-1793.48					
7	-1432.80	63.47	876165.60	33.01	41.71	36.54	-1710.13	89.52	1.49E+08	38.15	46.84	41.67
8	-1364.06	64.92	817563.90	32.65	42.56	36.67	-1652.41	54.52	1.70E+08	37.99	47.90	42.01
9	-1303.34	49.48	998411.60	32.43	43.56	36.94	-1588.99	51.67	1.98E+08	37.72	48.85	42.23
10	-1218.74	57.97	926659.60	31.77	44.12	36.78	-1504.19	58.10	1.83E+08	37.06	49.40	42.06
11	-1107.30	61.91	668089.00	30.62	44.18	36.11	-1397.73	59.14	1.45E+08	36.00	49.55	41.49
12	-914.22	**82.24 ***	**155619.0***	**27.95***	42.73	**33.94***	-1172.03	**96.13***	**18430130 ***	**32.72 ***	47.50	**38.71 ***

* pokazuje optimalan broj pomaka po određenom kriteriju	AIC: Akaike informacijski kriterij
LR: sekvencionalna modificirana LR test statistika svaki test pri 5%)	SC: Schwarz informacijski kriterij
FPE: Konačna greška predikcije	HQ: Hannan-Quinn informacijski kriterij

Izvor: Izrada autora.

Tablica P2.: Grangerov test kauzalnosti, sve zemlje

Grangerov test uzročnosti																	
Uzorak: 2007M01 2016M12		Njemačka		Francuska		Austrija		Slovenija		Hrvatska		Italija		Norveška		Rusija	
Pomaci: 12	Obs	F-Statistic	Prob.	F-Statistic	Prob.	F-Statistic	Prob.	F-Statistic	Prob.	F-Statistic	Prob.	F-Statistic	Prob.	F-Statistic	Prob.	F-Statistic	Prob.
CPI does not Granger Cause INDX	108	**2.78**	**0.00**	**2.01**	**0.03**	1.04	0.42	1.51	0.14	0.64	0.80	1.04	0.42	1.91	0.04	**1.84**	**0.05**
INDX does not Granger Cause CPI	108	0.69	0.75	0.73	0.72	1.25	0.26	**2.07**	**0.03**	**1.98**	**0.04**	0.95	0.51	0.99	0.47	0.49	0.92
EXR does not Granger Cause INDX	108	0.72	0.73	0.78	0.66	0.58	0.85	1.51	0.14	**1.83**	**0.06**	0.39	0.96	1.18	0.31	1.50	0.14
INDX does not Granger Cause EXR	108	0.95	0.50	0.87	0.58	0.88	0.57	0.92	0.53	0.36	0.97	1.25	0.26	**2.44**	**0.01**	0.74	0.71
IP does not Granger Cause INDX	108	**2.23**	**0.02**	**2.27**	**0.02**	0.79	0.66	**2.34**	**0.01**	0.74	0.71	1.36	0.20	**1.90**	**0.05**	0.58	0.85
INDX does not Granger Cause IP	108	0.91	0.54	**2.84**	**0.00**	**3.27**	**0.00**	**3.97**	**0.00**	**2.74**	**0.00**	**2.31**	**0.01**	1.33	0.22	**8.14**	**0.00**
IR does not Granger Cause INDX	108	**2.04**	**0.03**	**1.81**	**0.06**	1.53	0.13	**4.89**	**0.00**	1.14	0.34	1.13	0.35	**2.65**	**0.00**	0.75	0.69
INDX does not Granger Cause IR	108	**1.71**	**0.08**	**2.44**	**0.01**	**6.16**	**0.00**	**9.51**	**0.00**	**3.42**	**0.00**	**1.92**	**0.04**	**3.45**	**0.00**	**3.35**	**0.00**
PO does not Granger Cause INDX	108	0.91	0.54	1.23	0.27	1.18	0.31	**1.87**	**0.05**	**3.71**	**0.00**	1.34	0.21	**1.67**	**0.09**	1.26	0.26
INDX does not Granger Cause PO	108	0.95	0.50	1.40	0.18	**2.41**	**0.01**	1.33	0.22	1.60	0.11	1.14	0.34	**3.25**	**0.00**	**3.51**	**0.00**
QO does not Granger Cause INDX	108	**2.59**	**0.01**	**2.44**	**0.01**	1.09	0.38	1.06	0.41	0.71	0.73	1.03	0.43	**2.30**	**0.01**	**1.64**	**0.10**

INDX does not Granger Cause QO	108	1.31	0.23	0.77	0.68	0.43	0.95	1.32	0.22	0.92	0.53	1.08	0.39	1.08	0.39	0.50	0.91
EXR does not Granger Cause CPI	108	0.42	0.95	0.69	0.76	0.95	0.50	**1.83**	**0.06**	0.74	0.71	0.40	0.96	1.68	0.09	**3.00**	**0.00**
CPI does not Granger Cause EXR	108	0.64	0.80	0.76	0.69	0.67	0.78	0.66	0.79	1.31	0.23	1.17	0.32	**2.35**	**0.01**	**3.08**	**0.00**
IP does not Granger Cause CPI	108	**4.59**	**0.00**	**10.52**	**0.00**	**7.00**	**0.00**	**2.51**	**0.01**	**5.22**	**0.00**	**5.18**	**0.00**	**4.69**	**0.00**	**4.54**	**0.00**
CPI does not Granger Cause IP	108	**3.80**	**0.00**	**3.68**	**0.00**	**8.54**	**0.00**	**1.84**	**0.05**	**3.68**	**0.00**	0.86	0.59	1.81	0.06	**2.18**	**0.02**
IR does not Granger Cause CPI	108	1.29	0.24	1.75	0.07	1.15	0.34	1.24	0.27	1.31	0.23	0.85	0.60	0.55	0.87	0.91	0.54
CPI does not Granger Cause IR	108	1.59	0.11	0.92	0.53	0.94	0.51	**1.77**	**0.07**	1.13	0.34	**1.75**	**0.07**	1.18	0.31	0.82	0.63
PO does not Granger Cause CPI	108	**5.68**	**0.00**	**4.45**	**0.00**	**3.82**	**0.00**	**1.87**	**0.05**	**2.12**	**0.02**	**2.13**	**0.02**	1.16	0.32	0.77	0.67
CPI does not Granger Cause PO	108	0.69	0.76	0.44	0.94	0.97	0.48	0.90	0.55	0.73	0.72	0.38	0.97	1.25	0.27	1.11	0.36
QO does not Granger Cause CPI	108	1.52	0.13	1.53	0.13	0.90	0.55	0.69	0.75	1.04	0.42	**2.22**	**0.02**	**1.72**	**0.08**	**2.72**	**0.00**
CPI does not Granger Cause QO	108	**1.64**	**0.10**	1.60	0.11	1.38	0.19	1.50	0.14	0.95	0.50	1.24	0.27	1.42	0.17	1.35	0.21
IP does not Granger Cause EXR	108	0.97	0.48	1.40	0.18	0.78	0.67	**1.75**	**0.07**	1.15	0.33	1.22	0.28	0.72	0.73	**2.36**	**0.01**
EXR does not Granger Cause IP	108	0.61	0.83	0.87	0.58	0.57	0.86	1.35	0.21	**2.80**	**0.00**	0.79	0.66	1.05	0.41	**2.40**	**0.01**
IR does not Granger Cause EXR	108	0.94	0.51	0.94	0.51	0.94	0.51	0.94	0.51	0.53	0.89	0.94	0.51	0.93	0.53	1.50	0.14
EXR does not Granger Cause IR	108	1.30	0.23	1.30	0.23	1.30	0.23	1.30	0.23	0.86	0.59	1.30	0.23	**2.55**	**0.01**	0.47	0.93
PO does not Granger Cause EXR	108	0.94	0.51	0.94	0.51	0.94	0.51	0.94	0.51	1.06	0.41	0.94	0.51	1.04	0.42	1.49	0.14
EXR does not Granger Cause PO	108	1.11	0.36	1.11	0.36	1.11	0.36	1.11	0.36	0.89	0.57	1.11	0.36	1.57	0.12	0.70	0.74
QO does not Granger Cause	108	**2.01**	**0.03**	**2.01**	**0.03**	2.01	0.03	**2.01**	**0.03**	**2.06**	**0.03**	**2.01**	**0.03**	1.45	0.16	1.57	0.12

EXR																	
EXR does not Granger Cause QO	108	0.97	0.48	0.97	0.48	0.97	0.48	0.97	0.48	0.74	0.71	0.97	0.48	0.57	0.86	0.99	0.47
IR does not Granger Cause IP	108	**6.99**	**0.00**	**7.50**	**0.00**	**10.93**	**0.00**	**2.87**	**0.00**	**5.79**	**0.00**	**7.10**	**0.00**	0.95	0.50	**11.24**	**0.00**
IP does not Granger Cause IR	108	0.97	0.48	**1.68**	**0.09**	1.06	0.40	**1.90**	**0.05**	**2.69**	**0.00**	**3.28**	**0.00**	0.81	0.64	0.88	0.57
PO does not Granger Cause IP	108	**2.29**	**0.01**	**1.87**	**0.05**	**2.26**	**0.02**	1.13	0.35	**1.65**	**0.09**	**1.80**	**0.06**	0.71	0.74	**5.90**	**0.00**
IP does not Granger Cause PO	108	0.37	0.97	0.44	0.94	0.31	0.99	0.83	0.62	0.63	0.81	0.72	0.72	0.45	0.94	0.40	0.96
QO does not Granger Cause IP	108	0.96	0.50	**2.03**	**0.03**	**1.70**	**0.08**	**1.77**	**0.07**	**3.36**	**0.00**	**2.74**	**0.00**	1.09	0.38	1.17	0.32
IP does not Granger Cause QO	108	**1.97**	**0.04**	**2.53**	**0.01**	**1.97**	**0.04**	**2.63**	**0.01**	**1.83**	**0.06**	**2.56**	**0.01**	**1.81**	**0.06**	**2.27**	**0.02**
PO does not Granger Cause IR	108	**3.39**	**0.00**	**3.39**	**0.00**	**3.39**	**0.00**	**3.39**	**0.00**	0.94	0.51	**3.39**	**0.00**	**3.77**	**0.00**	**3.36**	**0.00**
IR does not Granger Cause PO	108	0.49	0.92	0.49	0.92	0.49	0.92	0.49	0.92	0.83	0.62	0.49	0.92	0.75	0.70	1.21	0.29
QO does not Granger Cause IR	108	1.47	0.15	1.47	0.15	1.47	0.15	1.47	0.15	1.39	0.19	1.47	0.15	1.53	0.13	1.44	0.17
IR does not Granger Cause QO	108	0.92	0.53	0.92	0.53	0.92	0.53	0.92	0.53	0.74	0.71	0.92	0.53	0.90	0.55	0.39	0.96
QO does not Granger Cause PO	108	1.29	0.24	1.29	0.24	1.29	0.24	1.29	0.24	1.29	0.24	1.29	0.24	1.29	0.24	1.29	0.24
PO does not Granger Cause QO	108	1.09	0.38	1.09	0.38	1.09	0.38	1.09	0.38	1.09	0.38	1.09	0.38	1.09	0.38	1.09	0.38

Izvor: Izrada autora.

SAŽETAK

U ovom radu analizirao se utjecaj cijena nafte na financijska tržišta, odnosno burzovne indekse. Ostale eksplanotorne varijable u modelu su: indeks potrošačkih cijena, indeks industrijske proizvodnje, tečaj domaće valute prema dolaru, kratkoročne kamatne stope i količina proizvedene nafte na svjetskom tržištu. Cilj rada bio je utvrditi, prema prvoj hipotezi postoji li utjecaj cijena nafte na burzovne indekse, te prema drugoj razlikuje li se taj utjecaj za zemlje uvoznice od zemalja izvoznica. U istraživanju je korišten VECM model za zemlje: Njemačka, Francuska, Austrija, Slovenija, Hrvatska, Italija, Norveška i Rusija. Također pri provođenju analize proveden je Phillips-Perronov test, te su sve varijable u svim modelima stacionarne pri I(1), dane su tablice u kojima je prikazana Gangerova kauzalnost, optimalna dužina pomaka i Johansenov test kointegracije. Koeficijenti VECM modela procijenjeni su metodom najmanjih kvadrata, te su dani grafovi koji prikazuju impulsne odgovore različitih burzovnih indeksa na povećanje cijene nafte (pozitivan šok).

SUMMARY

This paper analyzes the impact of oil prices on financial markets, more specific the stock market index. Other exploratory variables in the model are: consumer price indices, industrial production index, exchange rate of domestic currency against the dollar, short-term interest rates and the amount of oil produced in the world market. The aim of the paper was to determine, according to the first hypotheses, whether there is an influence of oil prices on stock market indexes, and whether the impact differs between net import and net export countries. The VECM model was used in the research for: Germany, France, Austria, Slovenia, Croatia, Italy, Norway and Russia. The Phillips-Perron test was also performed, and all variables in all stationary I(1), Ganger's causality has been shown in tables as well as the optimal lag length and Johansen's cointegration test. VECM coefficients are estimated by the least squares method. Graphs are showing the impulse responses of various stock market indices to rising oil prices (positive shock).