Analiza utjecaja izabranih varijabli na izvozne i uvozne cijene u Hrvatskoj

Bukovac, Dominik

Master's thesis / Diplomski rad

2018

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Pula / Sveučilište Jurja Dobrile u Puli**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:137:417760

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Image not found or type unknown

Repository / Repozitorij:

Digital Repository Juraj Dobrila University of Pula

zir.nsk.hr

Image not found or type unknown

Sveučilište Jurja Dobrile u Puli
Fakultet ekonomije i turizma
„Dr. Mijo Mirković“

DOMINIK BUKOVAC

ANALIZA UTJECAJA IZABRANIH VARIJABLI NA IZVOZNE I UVOZNE CIJENE U HRVATSKOJ

Diplomski rad

Pula, 2018.

Sveučilište Jurja Dobrile u Puli
Fakultet ekonomije i turizma
„Dr. Mijo Mirković“

DOMINIK BUKOVAC

ANALIZA UTJECAJA IZABRANIH VARIJABLI NA IZVOZNE I UVOZNE CIJENE U HRVATSKOJ

Diplomski rad

JMBAG: 0303041649, redoviti student
Studijski smjer: Ekonomija
Predmet: Makroekonomski management
Mentor: doc. dr. sc. Daniel Tomić

Pula, svibanj 2018.

IZJAVA O AKADEMSKOJ ČESTITOSTI

Ja, dolje potpisani _____, kandidat za magistra ekonomije/poslovne ekonomije ovime izjavljujem da je ovaj Diplomski rad rezultat isključivo mojega vlastitog rada, da se temelji na mojim istraživanjima te da se oslanja na objavljenu literaturu kao što to pokazuju korištene bilješke i bibliografija. Izjavljujem da niti jedan dio Diplomskog rada nije napisan na nedozvoljen način, odnosno da je prepisan iz kojega necitiranog rada, te da ikoji dio rada krši bilo čija autorska prava. Izjavljujem, također, da nijedan dio rada nije iskorišten za koji drugi rad pri bilo kojoj drugoj visokoškolskoj, znanstvenoj ili radnoj ustanovi.

Student

_____

U Puli, _____, _____ godine

IZJAVA

o korištenju autorskog djela

Ja, _____ dajem odobrenje Sveučilištu Jurja Dobrile
u Puli, kao nositelju prava iskorištavanja, da moj diplomski rad pod nazivom _____

_____

koristi na način da gore navedeno autorsko djelo, kao cjeloviti tekst trajno objavi u javnoj internetskoj bazi Sveučilišne knjižnice Sveučilišta Jurja Dobrile u Puli te kopira u javnu internetsku bazu završnih radova Nacionalne i sveučilišne knjižnice (stavljanje na raspolaganje javnosti), sve u skladu s Zakonom o autorskom pravu i drugim srodnim pravima i dobrom akademskom praksom, a radi promicanja otvorenoga, slobodnoga pristupa znanstvenim informacijama.

Za korištenje autorskog djela na gore navedeni način ne potražujem naknadu.

U Puli, _____ (datum)

Potpis

_____

SADRŽAJ

1. **UVOD** 1
2. **UVJETI RAZMJENE** 3
   2.1. Pojam i definicija 3
   2.2. Primjer uvjeta razmjene između dva partnera 4
   2.3. Razlika vanjske i unutarnje trgovine 5
   2.4. Povijesni aspekt i oblici uvjeta razmjene 6
   2.5. Načini izračuna uvjeta razmjene 8
   2.6. Izvozne i uvozne cijene 8
   2.7. Vanjskotrgovinska bilanca 10
3. **REALNI EFEKTIVNI TEČAJ** 14
   3.1. Vrste sustava deviznog tečaja 15
   3.2. Realni efektivni tečaj- pojam, definicija, izračun 18
   3.3. Tečajna politika Republike Hrvatske 18
4. **EMPIRIJSKA POZADINA** 21
5. **ANALIZA EKONOMETRIJSKOG MODELA** 27
   5.1. Metodološki pristup 27
   5.2. Stupanj integriranost vremenski serija 29
   5.3. Podaci 33
   5.4. Odabir vremenskih pomaka (lagova) i kointegracijskog ranga 37
   5.5. Dugi rok- Johansenova kointegracija 39
   5.6. Dekompozicija varijance i impulsne funkcije 40
   5.7. Kratki rok – uvjetni VEC model 44
   5.8. Evaluacija rezultata 46
6. **ZAKLJUČAK** 48

POPIS LITERATURE 51
POPIS TABLICA 55
POPIS GRAFIKONA 56
PRILOZI 57
SAŽETAK 67
SUMMARY 68

1. UVOD

Hrvatska kao malo, otvoreno gospodarstvo svoj nastup na međunarodnom tržištu ponajprije može pospješiti putem izvoza. Tako izvozna strategija predstavlja ključan faktor napretka gospodarstva. Stoga, važnost izvoznih i uvoznih cijena je važan faktor o kojem ovisi kretanje izvoza i uvoza. Promjene relativnih cijena imaju izravan i neizravan utjecaj na ekonomsku stabilnost i blagostanje jednog gospodarstva. Također, posebnost relativnih cijena je u tome jer je dinamika cijena dio globalnog mehanizma za zemlje koje su uključene u međunarodnu razmjenu.

Koncept uvjeta razmjene smatra se jednim od važnijih pokazatelja gospodarstva pojedine zemlje. Kako uvjeti razmjene prema definiciji predstavljaju odnos između izvoznih i uvoznih cijena, te se time i njihova analiza i kretanje važan pokretač gospodarskih aktivnosti. Uvjeti razmjene kao teorijski koncept svoj razvoj ima još kod ekonomista J. S. Milla. Osim teorijske pozadine uvjeta razmjene bitna stavka su i njegovi oblici, odnosno prihodovni i robni uvjeti razmjene. Osim, uvjeta razmjene i izvoznih i uvoznih cijena, bitan faktor predstavlja i realni efektivni tečaj koji prema definiciji predstavlja mjeru prosječnog trgovinskog vaganog tečaja valute prema košarici valuta koji je prilagođen razlikom u inflaciji u odnosu na druge zemlje.
Cilj ovog diplomskog rada je utvrditi utjecaj promjena prihodovnih uvjeta razmjene i realnog efektivnog tečaja na promjene izvoznih i uvoznih cijena. Odnosno, možemo prikazati dva cilja rada, koji će analizom modela biti i prikazani.

Prvi cilj. Utjecaj prihodovnih uvjeta razmjene i realnog efektivnog tečaja na izvozne cijene Republike Hrvatske
Drugi cilj. Utjecaj prihodovnih uvjeta razmjene i realnog efektivnog tečaja na uvozne cijene Republike Hrvatske.

Rad se sastoji od šest temeljnih poglavlja. Tako u prvom poglavlju, odnosno uvodu prikazane su metode izrade rada, ciljevi i hipoteze. Zatim drugim poglavljem, prikazan je koncept uvjeta razmjene preko teorijske pozadine. Prikazat će se povijesna perspektiva, definicija te načini izračuna uvjeta razmjene. Osim uvjeta razmjene prikazat će se i izvozne i uvozne cijene te njihov efekt sa uvjetima razmjene. Nakon toga, treće poglavlje predstavlja teorijsku pozadinu realnog efektivnog tečaja, odnosno prikazat će se vrste i podjela deviznih tečaja, te sa time i definicija realnog efektivnog tečaja. Četvrtim poglavljem prikazat će se teorijska pozadina,

odnosno biti će prikazana relevantna literatura koja se bavi problematikom uvjeta razmjene, tečajem te analizom izvoznih i uvoznih cijena. Teorijskom pozadinom analizirat će se radovi domaćih i stranih autora kako bi se dobila sveobuhvatna slika o promatranim varijablama i konceptima. Potrebno je naglasiti kako relevantna literatura vezana za tematiku ovog rada u Hrvatskoj nije toliko istražena, samim time prikazati će se najznačajniji autori i njihovi zaključci do kojih su došli analizom.

Nadalje, peto poglavlje predstavlja analizu ekonometrijskog modela i time ono predstavlja srž ovoga rada. U tome će se prikazati ekonometrijska analiza modela koja se temelji na Johansenovoj metodologiji za prikaz dugoročne analize, dok će kratki rok biti prikazan analizom uvjetnog VEC modele. Analiza modela temelji se na vremenskoj seriji od 17 godina, dakle od 2000. Q1 do 2017. Q2, odnosno analiza modela temelji se na kvartalnim podacima. Podaci su prikupljeni sa službene stranice Državnog zavoda za statistiku Republike Hrvatske (DZS), te sa Hrvatske narodne banke (HNB). Samim time, prikazati će se rezultati analize i napraviti poveznica sa istraženom empirijskom bazom ostalih autora. Također, uz prikaz modela biti će prikazani i grafikoni promatranih varijabli kako bi se dobio cjelokupni prikaz, ali i sa time prikazati će se testovi kvalitete modela, te dekompozicija varijance i impulsne funkcije. Šestim, zadnjim poglavljem prikazan će biti zaključak rada gdje će se prikazati rezultati istraživanja.

Na temelju prethodno definiranih ciljeva rada možemo definirati sljedeće hipoteze:
H1: Povećanje prihodovnih uvjeta razmjene utjecat će na povećanje izvoznih cijena, dok će realni efektivni tečaj utjecati na smanjenje izvoznih cijena.
H2: Povećanje uvjeta razmjene utjecat će na smanjenje uvoznih cijena, dok će realni efektivni tečaj utjecati na povećanje uvoznih cijena

Tijekom pisanja rada korištene su metode analize, sinteze, zatim komparativna metoda, deduktivna te istraživačka metoda. Osim metoda, tijekom pisanja rada korištena je znanstvena i stručna literatura (znanstveni članci, knjige, te internet izvori). Na temelju proučene literature i ekonometrijskog modela ovim radom prikazati će se važnost izvoznih i uvoznih cijena za Republiku Hrvatsku, odnosno prikazat će se važnost uvjeta razmjene ali i tečaja. Relevantnost ovog rada upravo se očituje u analizi navedenih varijabli gdje će se prikazati kakav efekt svaka od pojedinih varijabli ima za gospodarstvo hrvatske.

2. UVJETI RAZMJENE

Uvjeti razmjene predstavljaju važan dio makroekonomske politike, a posebice međunarodne ekonomije jer upravo uvjeti razmjene određuju i prikazuju kakvog će obujma biti međunarodna razmjena. Prilikom definiranja uvjeta razmjene možemo reći da predstavljaju količinu uvoza po jedinici izvoza, te mogu biti utvrđeni putem relativnih cijena izvoza i uvoza. Također, uvjeti razmjene teorijski gledano relevantno su objašnjenje u mnogim drugim makroekonomskim varijablama, odnosno utječu na promjene u investicijskoj perspektivi, uzrokuju nesigurnost štednje i potrošnje upravo zbog svoje volatilnosti, zatim djeluju kao kanal za tehnološki razvoj i utječu na brojne druge varijable. (Sharma i Tomić, 2012)

Posebice treba istaknuti da uvjeti razmjene odražavaju promjene u nacionalnoj proizvodnji i potrošnji koje proizlaze iz relativnih promjena cijena, te također utječu na nacionalnu konkurentnost i ono najvažnije na promjene izvoznih i uvoznih cijena. Povezanost gospodarskog rasta i uvjeta razmjene može se promatrati u dugom i u kratkom roku, no ona ovisi o tome kakva je struktura tržišta zemlje koju proučavamo, zatim kakve ekonomske politike provodi zemlja, da li je otvoreno ili zatvoreno gospodarstvo, kojim dobrima zemlja ostvaruje komparativnu prednost i mnogi drugi faktori koji određuju kako će zemlja nastupati na međunarodnom tržištu. Navedene činjenice imaju na zemlju direktne i indirektne utjecaje koje utječu na njezinu gospodarsku stabilnost (Hernandez, 2011).

2.1. Pojam i definicija

Prije detaljnije analize i proučavanja problematike uvjeta razmjene potrebno je definirati sam koncept uvjeta razmjene, pa tako prema Krugman i Obstfeld (2009) uvjeti razmjene predstavljaju vezu između relativnih cijena izvoza i uvoza jednog gospodarstva. Odnosno, uvjeti razmjene reflektiraju kapacitet izvoza potrebnog za kupovinu određenog uvoza zemlje. Važno za naglasiti je da razmjena može biti unutar zemlje ili izvan zemlje, odnosno unutarnja i vanjska razmjena ali je bitno da se ona promatra u suštini cijelog gospodarstva. Mogući problem koji se javlja prilikom uvjeta razmjene očituje se u tome ako jedan dio proizvodnje na primjer nije dostatan to se odražava i na ostale faze. Tako na primjer problemi koji se pojave u procesu proizvodnje utječu i na razmjenu i na potrošnju, ali i problemi koji nastaju u fazi razmjene odražavaju se i na proizvodnju i potrošnju (Babić i Babić, 2008).

Kako je navedeno da uvjeti razmjene predstavljaju važan faktor međunarodne ekonomije, analogno tome postavljaju se dva važna pitanja za međunarodnu razmjenu:

1. Koja će dobra određena zemlja izvoziti?
2. Po kojim će se uvjetima odvijati međunarodna razmjena?

Prvo pitanje odnosi se na komparativnu prednost zemlje, dok drugo pitanje predstavlja pojam uvjeta razmjene. Uz navedeno, važnu ulogu u određivanju uvjeta razmjene i ostvarivanja komparativne prednosti imaju upravo relativne cijene dobara kojima zemlje raspolažu i upravo na takav način izvršavaju obostrano korisnu razmjenu. Daljnjim slijedom rada bit će prikazan primjer razmjene između dva partnera, odnosno prikazan će biti koncept komparativne prednosti.

2.2. Primjer uvjeta razmjene između dva partnera

Slijedom rada bit će prikazan primjer uvjeta razmjene između dva partnera. Pretpostavimo da imamo dva partnera, partnera A i partnera B. Partner A raspolaže određenim viškom dobra X, dok partner B raspolaže određenim viškom dobra Y. Uz navedeno stvoren je temeljni uvjet kako bi se razmjena mogla izvršiti. Nadalje, pretpostavimo da je partner A voljan razmjenjivati dobro X kojim raspolaže, te on mora prvo zadovoljiti potrebe za navedenim dobrom. Što je veći stupanj zadovoljstva za dobrom X to mu je potrošnja dodatne jedince navedenog dobra sve manja, odnosno donosi mu sve manje koristi i iz toga razloga voljan je razmjenjivati dobro X s dobrom Y. Isto vrijedi i za partnera B koji ima višak proizvoda Y i želi ga razmjenjivati za neko drugo dobro na primjer za dobro X.

Kako bi proces razmjene krenuo i bio uspješan, dobro Y treba imati korisnost za partnera A, a dobro X treba imati korisnost za partnera B. Također, uz navedeno potrebno je i da jedinica dobra Y koju proizvodi partner B ima veću korisnost za partnera A od jedinice dobra X koju on proizvodi. Tako i za drugog partnera, jedinica dobra X treba za partnera B imati veću korisnost od jedinice dobra Y.

Partner A daje partneru B dobro X, određen iznos dobra X u zamjenu za određenu količinu dobra Y. Odnos količine dobra X i količine dobra Y zove se uvjet razmjene. Tako na primjer ako partner A daje partneru B 10 jedinica dobra X za 20 jedinica dobra Y, odnos razmjene je dvije jedinice dobra Y za jednu jedinicu dobra X. Prema tome jedna jedinica dobra X košta

dvije jedinice dobra Y. Time je dokazano da cijena svakog dobra može biti izražena u terminima drugog dobra (Babić i Babić, 2008).

2.3. Razlika vanjske i unutarnje trgovine

Kako uvjeti razmjene predstavljaju široki pojam i obuhvaćaju mnoge aspekte gospodarstva, potrebno je objasniti iste. Tako važan dio predstavlja vanjska i unutarnja trgovina. Dakle, prvenstveno treba navesti razliku između otvorenog i zatvorenog gospodarstva, gdje otvoreno gospodarstvo obavlja međunarodne transakcije kao što su transakcije robama i uslugama, kapitalom i tako dalje. Dok s druge strane, zatvoreno gospodarstvo koje se zove još i autarkično u potpunoj je suprotnosti otvorenom gospodarstvu. Uz navedeno potrebno je istaknuti koje su prednosti i nedostaci vanjske i unutarnje trgovine ali i njihove razlike.

Kao najvažniju razliku između unutarnje i vanjske trgovine klasični ekonomisti su smatrali nemobilnost faktora proizvodnje, no ipak postoje određene nesuglasice u vezi navedene tvrdnje. Naime, možemo naglasiti kako ne postoji potpuna mobilnost unutar zemlje zbog zatvorenosti regija, dok s druge strane postoji kretanje kapitala i rada. Tako je John Stuart Mill zaključio da u situaciji međuregionalne nemobilnosti proizvodnih faktora teorija vanjske trgovine je primjenjiva u analizi međuregionalne trgovine, a da bi u slučaju potpune mobilnosti proizvodnih faktora rada i kapitala na međuregionalnoj razini posebna teorija vanjske trgovine bila suvišna (Grgić i Bilas, 2008).

Sljedeća u nizu razlika između vanjske i unutarnje trgovine upravo je valuta plaćanja. Naime, unutar neke zemlje plaćanja se vrše putem domaće valute, dok za međunarodnu razmjenu potrebna je strana valuta. Za zaključak navedenog možemo reći da se razmjena između država može odvijati jedino ako je domaća valuta konvertibilna za valute drugih država. Osim navedenih razlika potrebno je napomenuti i ostale od kojih se ističu: različitost monetarnih sustava zemalja i postojanje političkih granica pojedinih država partnera u vanjskoj trgovini. Posljednjom zadnjom razlikom ističe se da kod vanjske trgovine postoje veći transportni troškovi između partnera, nego li je to slučaj u unutarnjoj razmjeni. Možemo zaključiti da je s navedenim činjenicama vanjska trgovina bitan faktor razvoja gospodarstva svake pojedine zemlje.

2.4. Povijesni aspekt i oblici uvjeta razmjene

Narednim potpoglavljem prikazat će se koncept razvoja uvjeta razmjene kroz povijesnu perspektivu, odnosno od samih početaka kada se je počelo govoriti o uvjetima razmjene. Također, navedeni će biti i objašnjeni oblici uvjeta razmjene koji postoje. Uvjete razmjene kao termin koji je danas prisutan po prvi puta se javio u radu J.S. Milla koji je termin uvjeta razmjene povezao s razmjenom dvaju dobara koja se razmjenjuju između dvije zemlje. Nadalje, razvili su se i ostali oblici uvjeta razmjene od kojih se ističu robni i prihodovni uvjeti razmjene. Tako, robni uvjeti razmjene predstavljaju najčešće korišten oblik uvjeta razmjene, odnosno koji u obzir uzimaju odnos između izvoznih i uvoznih cijena dobara, ali ne i usluga. S druge strane, postoje i prihodovni uvjeti razmjene koji se objašnjavaju kao postotno izražen odnos vrijednosti izvoznih i uvoznih cijena koji je veoma važan pokazatelj za zemlje u razvoju. Važno za naglasiti je sljedeće, ukoliko je vanjskotrgovinska razmjena u ravnoteži tada će prihodovni uvjeti razmjene biti jednaki volumenu uvoza. Prikazom prihodovnih uvjeta razmjene možemo doći do zaključka da li zemlja ostvaruje neto korist ili neto gubitke prilikom promjena u uvjetima razmjene (Mendoza, 1997).

Osim navedena dva oblika uvjeta razmjene, potrebno je navesti i jednostruke i dvostruke uvjete razmjene. Njihov izračun je kompleksan no oni su teorijski bolji u odnosu na ostale oblike. Ono što uzimaju u obzir jesu procjene uvozne sposobnosti zemlje i produktivnost u izvoznom i uvoznom sektoru. Tako jednostruki faktorski uvjeti razmjene određeni su umnoškom robnih uvjeta razmjene i indeksa domaće produktivnosti. S druge strane, dvostruko faktorski uvjeti razmjene uzimaju u obzir i indeks strane produktivnosti, te su određeni umnoškom uvjeta razmjene i odnosa domaće i strane produktivnosti (Fleming, 2007).

Uz navedene oblike uvjeta razmjene važna napomena što se tiče uvjeta razmjene može se reći da su oni široki i opsežan pojam, ali usprkos tome postoje i ograničenja. Tako, uvjeti razmjene ne opisuju volumen razmjene nego samo relativne promjene u cijenama dobara. Kako se uvjeti razmjene sagledavaju prvenstveno putem relativnih promjena izvoznih i uvoznih cijena za detaljniju analizu potrebno bi bilo sagledati i ostale važne faktore (produktivnost, alokacija resursa, volumen razmjene i sl.).

Osim J.S. Milla termin uvjeta razmjene može se naći i u djelu A. Smitha „Bogatstvo naroda“ koja podsjeća kako su relativne cijene izvoza i uvoza esencijalna pretpostavka merkantilističke

strategije ostvarivanja većih razina bogatstva. Također Mill je prvi ekonomist koji je radio analizu odrednica uvjeta razmjene, a kasnije je A. Marshall razvio koncept krivulje ponude izvoza, te pokazao kako je višak u ponudi i potražnji dvaju dobara koja se razmjenjuju između dvije zemlje upravo funkcija promjene u uvjetima razmjene.

Od ostalih ekonomista ne smije se izostaviti i doprinos D. Ricarda koji tvrdi da ravnoteža u međunarodnoj razmjeni ne ovisi o promjeni valute , nego navodi da poremećaj neravnoteže dolazi zbog promjene carinske tarife. Nadalje, A. Marshallov doprinos je analiza recipročne potražnje ali i novi sustav prikaza ponude i potražnje, odnosno dijagram ponude i potražnje. D. Hume je smatrao kako će relativne promjene u količini novca jedne zemlje u odnosu na druge, rezultirati rastom cijena sve dok se ne uspostavi međunarodna ravnoteža. Osim navedenih doprinosa ekonomista o uvjetima razmjene postoje i mnogi drugi, no od posebne važnosti ipak treba navesti doprinos Singera i Prebisha. Njihov najpoznatiji doprinos je upravo Singer – Prebisheva hipoteza gdje koristi od razmjene idu u korist razvijenih zemalja, a na štetu nerazvijenih zemalja i zemalja u razvoju (Tomić, 2012).

Osim prethodno definiranih podjela uvjeta razmjene i njihovog povijesnog razvoja potrebno se je osvrnuti i na učinke koje uzrokuju uvjeti razmjene. Tako prema istraženoj i proučenoj literaturi Henry (2006) navodi sljedeće utjecaje:

1. Proizvodnja u sektoru primarnih dobara se povećava, uslijed čega dolazi do smanjenja proizvodnje u sektoru proizvedenih dobara.
2. Potrošači ostvaruju veći probitak iz razloga što imaju veći realni dohodak. Time se povećava njihova potražnja za proizvedenim dobrima, no utjecaj na njihovu potražnju za domaćim primarnim dobrima je neodređen.
3. Volumen razmjene se povećava, te sa time se povećava volumen uvoza proizvedenih dobara i izvoza primarnih dobara.
4. Sektor proizvodnje primarnih dobara zapošljava sve veći udio nacionalnog rada i kapitala.
5. Realne plaće se smanjuju neovisno po kojoj proizvodnoj cijeni korigiramo nominalne plaće.
6. Produktivnost kapitala raste
7. Udio rada u BDP-u pada, dok raste udio profita.

Prema proučenoj literaturi možemo zaključiti kako su uvjeti razmjene bitan faktor napretka hrvatskog gospodarstva. Možemo zaključiti kako se uvjeti razmjene u Hrvatskoj poboljšavaju, a ne pogoršavaju. Daljnjim slijedom rada prikazati će se problematika uvjeta razmjene u Hrvatskoj iz razloga da se dobije potpunija slika istih, te naravno zbog toga što su upravo uvjeti razmjene glavna stavka rada koju promatramo u istraživačkom dijelu.

2.5. Načini izračuna uvjeta razmjene

Kako prema definiciji uvjeti razmjene predstavljaju količinu uvoza po jedinici izvoza samim time izračun uvjeta razmjene se temelji na odnosu izvoznih i uvoznih cijena. Broj koji dobijemo odnosom izvoznih i uvoznih cijena pomnožimo sa 100 kako bi dobili postotak uvjeta razmjene. Ako rezultat prelazi 100% tada kažemo da se zemlja nalazi u dobrom gospodarskom stanju, ako je rezultat manji od 100% kažemo da zemlja ima negativno stanje, odnosno da više novca izlazi iz gospodarstva nego što ulazi u njega. Izračun uvjeta razmjene može se učiniti na dva načina. Prvi model predstavlja dvije zemlje, dok se drugi odnosi na model s više zemalja. Osvrtom na prvi model, odnosno model s dvije zemlje koje razmjenjuju dva dobra možemo reći da predstavlja pojednostavljen pristup. Odnosno, uvjet razmjene se računa odnosom izvoznih i uvoznih cijena. S druge strane, ako imamo model s više zemalja takav pristup je složeniji i uvjeti razmjene se računaju pomoću određenih indeksa. (npr. Fisherov indeks). Osim navedenih pristupa uvjeta razmjene može se računati i za bruto domaći proizvod kao deflatora nominalne vrijednosti ukupnog izvoza ili uvoza dobara i usluga (Tomić, 2012).

2.6. Izvozne i uvozne cijene

Današnja situacija međunarodne razmjene postaje sve kompleksnija i zahtjevna za svaku pojedinu zemlju. Važno je napomenuti kako zemlje u današnjici ako žele ostvariti gospodarski rast moraju biti otvorene zemlje, odnosno poslovati kao otvoreno gospodarstvo, a ne kao zatvoreno. Čimbenici koji utječu na rast otvorenog gospodarstva su upravo uvjeti razmjene.
Mnoge rasprave vode se po pitanju međunarodne razmjene i gospodarskog rasta. Tako postoje dva osnovna pitanja vezana uz navedenu dinamiku:

- Predstavlja li gospodarski rast zemalja partnera u razmjeni korisnu stvar za jednu zemlju.
- Je li gospodarski rast više ili manje koristan kada je zemlja dio umreženog svjetskog gospodarstva (Sharma i Tomić, 2012).

Gospodarski rast može biti koristan iz razloga povećanja blagostanja neke zemlje, ali s druge strane može doći do stvaranja konkurencije. Rast proizvodnih kapaciteta trebao bi biti koristan za zemlju jer na takav način zemlja svoje viškove može prodati na svjetskom tržištu, ali navedeno bi koristilo i strancima prvenstveno zbog nižih cijena izvoza. Kako bi se utvrdio pravilan efekt na gospodarski rast, naravno treba sagledati uvjete razmjene, odnosno utjecaj na relativne cijene (Sharma i Tomić, 2012).

Kada se postavlja pitanje što zapravo predstavljaju uvjeti razmjene, možemo zaključiti da predstavljaju vezu između relativnih cijena izvoza i uvoza jednog gospodarstva, odnosno uvjeti razmjene reflektiraju kapacitet izvoza potrebnog za kupovinu određenog uvoza zemlje. Ono što se želi postići uvjetima razmjene je upravo veza između cijena po kojima zemlja izvozi i cijena koje plaća za svoj uvoz.

Dakle, porast izvoznih cijena (pad uvoznih cijena) rezultirat će poboljšanju uvjeta razmjene, odnosno pad izvoznih cijena (rast uvoznih cijena) imat će za posljedicu pogoršanje uvjeta razmjene. Također, tržište može uzrokovati istovremeno kretanje izvoznih i uvoznih cijena, a efekt koji će prevladati bit će od onih cijena čiji efekt je veći. Znači, ako izvozne cijene jedne zemlje rastu relativno u odnosu na uvozne cijene, kažemo da se uvjeti razmjene za tu zemlju poboljšavaju time da ona ostvaruje više jedinica uvoza po svakoj jedinici izvoza (Tomić, 2012).

Ako razmatramo povezanost uvjeta razmjene i gospodarskog rasta možemo zaključiti kako je navedeno kompleksan sustav zato što ovisi o brojnim čimbenicima. Među važnijim čimbenicima ističu se: tržište zemlje, promjene u relativnim cijenama, otvorenost gospodarstva, devizni tečaj i mnogi drugi. Navedeni utjecaj koji može nastati povećanjem ili smanjenjem izvoznih i uvoznih cijena, a u slijedu rada sada će biti prikazani utjecaj deviznog tečaja.

Izvozne cijene mogu biti pogoršane zbog promjena u vrijednosti nacionalne valute koja je određena promjenama u kamatnoj stopi. Naime, ako se uslijed rasta kamatne stope, vrijednost valute neke zemlje poveća, očekuje se i poboljšanje uvjeta razmjene. Navedeno može predstavljati dvosjekli mač zato što rast izvoznih cijena može dovesti do pada inozemne potražnje za domaćim proizvodima te rezultirati padom opsega izvoza. Navedeno ima negativan efekt jer izvoznici imaju slabiju konkurentsku poziciju na međunarodnom tržištu iako su uvjeti razmjene pogodniji (Sharma i Tomić, 2012).

Teoretski gledano, ako vrijednost nacionalne valute raste to bi trebalo dovesti do poboljšanja uvjeta razmjene, dok s druge strane pad vrijednosti nacionalne valute trebao bi dovesti do pogoršanja uvjeta razmjene. Deprecijacija, odnosno devalvacija ne mora štetiti zemlji. Ako je izvoz konkurentniji može doći do gospodarskog rasta u dugom roku. Promjene u uvjetima razmjene mogu imati značajan efekt na realni nacionalni dohodak ako se proizvodnost ne mijenja, a deprecijacija mijenja produktivnost putem realokacije resursa. No, s druge strane iako devalvacija negativno utječe na uvjete razmjene ipak može utjecati na racionalnije korištenje resursa koji dovode do veće produktivnosti (Lee i Kennedy, 2009).

Osim pojmovnog određenja izvoznih i uvoznih cijena te njihovog značaja za gospodarstvo potrebno je objasniti kako se definira izvođenje izvoznih i uvoznih cijena. Postoje dva pristupa na koji se mogu odrediti cjenovne vrijednosti izvoza i uvoza. Prvi pristup je putem indeksa cijene te podrazumijeva izračunavanje izvoznih i uvoznih cijena kao indeks jediničnih vrijednosti. Odnosno, izračunava se indeks promjene vrijednosti izvoza i uvoza po količinskoj jedinici izvezenih ili uvezenih proizvoda, odnosno po kilogramu kao jedinstvenoj i usporedivoj količinskoj jedinici za sve proizvode. Ovaj pristup ne pruža uvid u uvozne i izvozne cijene usluga. Drugi pristup temelji se na deflatoru cijena, odnosno podrazumijeva izračunavanje izvoznih i uvoznih cijena kao deflatora nominalne vrijednosti ukupnog izvoza ili uvoza dobara i usluga iz nacionalnih računa. Razlika između ovoga i prethodnog pristupa očituje se u tome da navedeni pristup omogućuje uključivanje vrijednosti usluga u izračun izvoznih i uvoznih cijena.

2.7. Vanjskotrgovinska bilanca

Kako je navedeno da uvjeti razmjene kao koncept imaju značajan utjecaj na gospodarstvo tako utječu i na vanjskotrgovinsku bilancu pojedine zemlje jer se upravo vanjskotrgovinska bilanca očituje uvjetima razmjene. Prije same analize vanjskotrgovinske bilance potrebno se osvrnuti na izvoz i uvoz dobara i usluga. Tako izvoz roba i usluga predstavlja kategoriju finalne potrošnje kao i investicije, osobna i opća potrošnja. Povećanje izvoza roba i usluga imat će pozitivan utjecaj na bruto domaći proizvod. Drugim riječima, izvoz u situaciji nepotpune zaposlenosti ima multiplikativni efekt na domaći proizvod ali i na ostale dijelove autonomne potrošnje.

S druge strane, uvoz dobara i usluga ne uzrokuje multiplikativni efekt na bruto domaći proizvod kao što je to u slučaju izvoza roba i usluga. Odnosno, u situaciji nepotpune zaposlenosti tj. kada je domaći proizvod manji od potencijalnog, uvoz roba i usluga predstavlja gubitak multiplikativnog efekta koji bi nastao supstitucijom uvoza domaće proizvodnje (Babić, 1995).

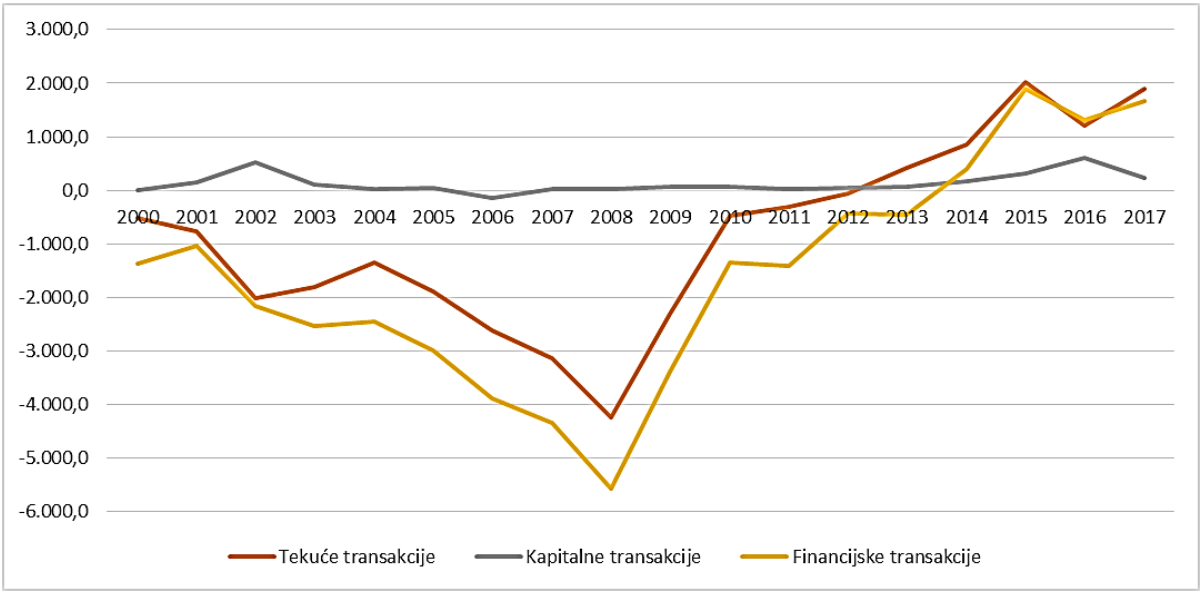
Osim navedenog jedan dio uvoza se ne može zamijeniti domaćom proizvodnjom. Takav uvoz zove se nekonkurentni uvoz. Potrebno je naglasiti odnos između uvoza i domaće proizvodnje koji se zove prosječna sklonost uvozu i koja pokazuje veličinu uvoza koja je prosječno uvjetovana jedinicom domaćeg proizvoda. Pored prosječne sklonosti uvozu postoji i granična sklonost uvozu koja pokazuje veličinu uvoza koju uvjetuje jedinično povećanje proizvodnje. Potrebno je objasniti još i elastičnost uvoza koja se prikazuje kao odnos između granične i prosječne sklonosti uvozu. Koeficijent nam pokazuje za koliko posto će porast uvoz ako Y poraste za 1 %. Odnosno, ako je granična sklonost uvozu manja od prosječne onda je elastičnost uvoza naspram domaćeg proizvoda manja od jedan (Babić, 1995).

Nakon što je objašnjen odnos izvoza i uvoza roba i usluga te njihovi mogući efekti na gospodarstvo u daljnjem slijedu rada stavit će se naglasak na vanjskotrgovinsku bilancu (u daljnjem slijedu rada VTB). Prije analize VTB potrebno je objasniti kakav ona efekt ostvaruje, znači ako je izvoz dobara i usluga veći od uvoza dobara i usluga tada je VTB veća od 0 i ostvaruje se suficit, u suprotnome kada je izvoz roba i usluga manji od uvoza roba i usluga tada je VTB manja od 0 i ostvaruje se deficit (Kovač, 2012).

Vanjskotrgovinska politika RH određena je najvećim dijelom Svjetske trgovinske organizacije i Europske unije. Naime, Hrvatska se ulaskom u EU obvezala primjenjivati Zajedničku trgovinsku politiku. Kako je Hrvatska mala zemlja, trgovinska politika predstavlja jedan od ključnih faktora njezina razvoja. Tako su izvoz dobara i usluga Hrvatske najvažniji za njezinu vanjskotrgovinsku politiku. Kako izvozna strategija predstavlja važan faktor napretka gospodarstva važnu ulogu u tome imaju izvozne i uvozne cijene. Zemlje u razvoju podložene su promjenama cijena na svjetskom tržištu. Tako izvozne i uvozne cijene Hrvatske su podložne promjenama na međunarodnoj razini. Promjene u nacionalnoj proizvodnji često su povezane s relativnim kretanjima cijena. Tako povećanje izvoznih cijena koje pogoduju određenom sektoru gospodarstva dovode do povećanja ulaganja u taj sektor. Visoki izvoz / uvoz u omjeru bruto domaćeg proizvoda predstavlja važan aspekt kako izvozne i uvozne cijene oblikuju hrvatsku trgovinsku politiku. Nažalost postoje određeni problemi i prepreke vođenja trgovinske politike

RH. Među najgorim preprekama navode se: usitnjena proizvodnja hrvatskog gospodarstva, nedostatni kapaciteti, neadekvatna izvozna strategija, problemi transfera tehnologije i teži pristup kapitalu. Jedan od primarnih ciljeva RH je postići konkurentnost na međunarodnom tržištu kako bi postala što više izvozno orijentirana zemlja, ali i što konkurentnija. Uz sve navedeno sve veći naglasak se stavlja na jačanje izvoza kao strateškog cilja napretka cijelog gospodarstva (Turčić, 2014).

Grafikon 1. Platna bilanca Republike Hrvatske



Izvor: Izrada autora prema www.hnb.hr

Grafikon 1. prikazuje platnu bilancu Republike Hrvatske za razdoblje od 2000 pa do 2017. Platna bilanca Hrvatske prikazana je prema njezinim glavnim stavkama. Dakle, na grafikonu su prikazane tekuće transakcije, kapitalne transakcije i financijske transakcije. Prije same analize grafičkog prikaza potrebno se ukratko osvrnuti općenito na platnu bilancu. Dakle, platna bilanca Republike Hrvatske sistematičan je prikaz vrijednosti ekonomskih transakcija hrvatskih rezidenata s nerezidentima u određenom razdoblju. Sastavlja se u skladu s metodologijom koju je preporučio Međunarodni monetarni fond (MMF) i prihvatila Europska unija. Ukoliko se osvrnemo na grafički prikaz, vidimo da postoje određena odstupanja kod pojedinih stavki platne bilance. Dakle, ukoliko promatramo kapitalne transakcije, možemo zaključiti kako nemaju određeni trend povećanja niti smanjenja. Odnosno, od 2016. godine kapitalne transakcije su zabilježile najveće smanjenje. Druga stavka platne bilance koja je prikazana na grafičkom

prikazu su tekuće transakcije. Prije same analize tekućih transakcija potrebno je navesti njezine komponente. Tako se tekuće transakcije sastoje od sljedećih komponenata: roba, usluga i primarnog dohotka, robe i usluge, robe, usluge, primarni dohodak i na kraju sekundarni dohodak. Iz analize grafičkog prikaza, možemo zaključiti kako su tekuće transakcije oscilirale u promatranom vremenu. Dakle, od 2000. pa sve do 2012. godine tekuće transakcije su u deficitu. Nakon toga, zabilježen je suficit kod tekućeg računa. Potrebno je navesti da je najveći deficit tekućih transakcija zabilježen 2008. godine, što je naravno uzročnik bila financijska kriza. Kako je napomenuto da su 2012. godine tekuće transakcije u deficitu, ujedno treba napomenuti da se od 2008. godine počeo smanjivati. I na kraju, financijske transakcije čine izravna ulaganja, portfeljna ulaganja, financijske izvedenice i ostala ulaganja. Na temelju grafičkog prikaza možemo zaključiti kako su financijske transakcije od 2000. pa sve do 2014. godine bile u deficitu, a nakon toga su u suficitu. Također, najveći deficit ostvaren isto kao i kod tekućih transakcija, dakle 2008. godine. Nakon 2008. godine financijske transakcije bilježe smanjenje deficita.

3. REALNI EFEKTIVNI TEČAJ

Tečajna politika predstavlja važan čimbenik makroekonomske stabilnosti u zemlji. Prvenstveno treba definirati devizni tečaj pa tako prema Babić i Babić (2008) devizni tečaj predstavlja cijenu jedne jedinice strane valute izraženu brojem jedinica domaće valute, odnosno prikazuje koliko jedinica domaće valute treba platiti za jednu jedinicu strane valute. Navedeno predstavlja sustav direktnog kotiranja, dok sustav indirektnog kotiranja primjenjuje samo Velika Britanija, pa se tamo devizni tečaj definira kao broj jedinica strane valute koji treba dati za jedinicu domaćeg novca. (Perišin, Šokman i Lovrinović, 2001) Kako je navedeno da je devizni tečaj jedan od bitnijih faktora svake zemlje, također uz navedeno treba navesti kako je on odraz različitih politika svake zemlje. Tako mnoge države upravo za cilj imaju stabilnost tečaja i cijena u svome gospodarstvu. Daljnjim slijedom rada bit će prikazane vrste deviznih tečaja i njihove prednosti i nedostaci s posebnim osvrtom na realni efektivni tečaj.

Posebno treba istaknutu kako je politika deviznog tečaja otvorenih gospodarstava ključni makroekonomski pokazatelj zemalja zato što utječe na investicije. Navedeno se odražava na devizni tečaj putem izvoza i uvoza utječe na politike što u konačnici može dovesti do smanjenja deficita vanjske trgovine (Chounduri i Hakura, 2012).

Fluktuacija tečaja može uzrokovati niz promjena u izvoznim i uvoznim cijenama, zatim može utjecati na indeks proizvođačkih cijena ali i na indeks potrošačkih cijena neke zemlje. Kako bi se utvrdio učinak deviznog tečaja potrebno je otkriti efekte koji utječu na njih (izvozne i uvozne cijene). Snaga utjecaja tečaja na promjene cijena ima nekoliko važnih učinaka . Naime, ako je prolazni učinak visok tečaj ne utječe na trgovinsku bilancu, dok s druge strane ako je prolazni učinak nizak promjene tečaja mijenjaju relativne cijene razmjenjivih i ne razmjenjivih dobara. Uz sve navedeno, utjecaj na vanjsku ravnotežu očituje se i kroz uvjete razmjene ali i putem realnog efektivnog tečaja (Dash i Narasimhan, 2011).

Uz sve navedeno zanimljivo je i potrebno navesti kakav utjecaj tečaj ima na vanjskotrgovinsku bilancu neke zemlje. Upravo tako zanimljivo istraživanje je Begović i Krešo (2017) koji istražuju učinak realnog efektivnog tečaja za tranzicijske zemlje u Europi za razdoblje 2000.-2015. godine. Autori dolaze do zaključka da deprecijacija realnog efektivnog tečaja dovodi do pogoršanja trgovinske ravnoteže u europskim tranzicijskim zemljama. Razlog tome ističe se da

su tranzicijske zemlje visoko uvozno orijentirane, te imaju mali kapacitet izvoza. Ukoliko sagledamo teorijske aspekte, devalvacija bi trebala smanjiti trgovinski deficit jer uvoz postaje skuplji, a izvoz jeftiniji. No usprkos tome, ukoliko postoji visoki uvoz i sa time nedostatni kapaciteti za izvoz i za postizanje konkurentnosti, devalvacija tečaja bi u kratkom roku izazvala negativan učinak. Naime, ukoliko su elastičnosti cijene niske, učinak realnih promjena tečaja bi vjerojatno bio nepovoljan, te ukoliko su neelastičnosti prisutne u zemlji time trgovinska bilanca neće imati koristi od realnog efektivnog tečaja budući da će uvoziti isti iznos ali po većim cijenama te izvoziti isti iznos ali po nižim cijenama.

Analogno prethodnom prikazanom istraživanju možemo se nadovezati na sljedeće. Naime, Stučka (2004) navodi kako bi se utvrdio učinak potrebno je sagledati kratkoročnu i dugoročnu analizu utjecaja promjene tečaja na trgovinsku bilancu. Uravnoteženje dugoročnih i kratkoročnih promjena robnih razmjena u odnosu na promjene tečaja su važne iz nekoliko razloga. Prvo, utvrđuje se postoji li stabilan dugoročni odnos između tečaja i bilance robne razmjene. Ukoliko, stabilan dugoročni odnos ne postoji onda deprecijacija tečaja nije najprikladniji odabir za poboljšanje konkurentnosti zemlje. Drugo, ukoliko postoji dugoročni odnos, tada je potrebno utvrditi kada deprecijacija vodi ka poboljšanju trgovinske bilance u dugom roku. Treće, ukoliko bi postojalo uravnoteženje trgovinske bilance, omogućilo bi se sagledavanje troškova i koristi. I na kraju četvrto, procjenom kretanja tečaja dolazimo do informacija o srednjoročnim utjecajima na trgovinsku bilancu. Kratkoročnim utjecajem pokušava se procijeniti koliki će štetan utjecaj imati tečaj.

3.1. Vrste sustava deviznog tečaja

Prije objašnjenja vrsta deviznog tečaja potrebno je navesti i objasniti termine kao što su: nominalni devizni tečaj, realni devizni tečaj i efektivni devizni tečaj. Tako nominalni devizni tečaj predstavlja promjenu cijene domaće valute izraženu u stranoj valutu bez inflacije. S druge strane, realni devizni tečaj predstavlja nominalni tečaj korigiran za stopu inflacije i on je mnogo važniji zato što inflacija umanjuje vrijednost novca. Na kraju, efektivni devizni tečaj je vagani prosjek deviznih tečajeva između domaće valute i valuta zemalja najvažnijih trgovačkih partnera (Perišin, Šokman i Lovrinović, 2001).

Naredni dio rada prikazat će sustave deviznog tečaja pa tako Koški (2008) navodi da prema Međunarodnom monetarnom fondu tečajevi mogu biti sljedeći:

1. Sustav bez domaće valute u optjecaju – kod sustava domaće valute u optjecaju sredstvo plaćanja služi strana valuta (npr. dolar ili euro). Kod navedene vrste zemlje ne mogu voditi samostalnu monetarnu politiku, nego vode zajedničku monetarnu politiku, odnosno stvaraju monetarnu uniju.
2. Valutni odbor – valutni odbor je monetarni režim, odnosno monetarna institucija u kojoj se monetarne vlasti, temeljem zakonskih propisa obvezuju emitirati primarni novac samo do iznosa vrijednosti međunarodnih pričuva kojim raspolažu.
3. Sustav konvencionalno vezanoga deviznog tečaja – u sustavu konvencionalnog vezanog deviznog tečaja vrijednost domaće valute vezana je barem tri mjeseca za odabrani denominator uz mogućnost fluktuacije od 1%. Danas je ovaj sustav postao jedan od najzastupljenijih sustava deviznih tečajeva.
4. Sustav vezanog deviznog tečaja u okvirima horizontalnog raspona – posebnost ovog sustava očituje se u tome da vrijednost domaće valute ima mogućnost fluktuacije veću od 1% od vrijednosti pariteta. Naravno, ukoliko bi tečajne fluktuacije bile do 1% tada bi bilo riječi o konvencionalno-vezanom deviznom tečaju.
5. Sustav puzećega vezanja deviznog tečaja – sustav puzećega vezanja deviznog tečaja razlikuje se po tome što prema unaprijed poznatom obrascu monetarne vlasti prilagođavaju paritet domaće valute i to u malim fiksnim iznosima ili u odnosu na neke odabrane makroekonomske pokazatelje kao što je na primjer razlika inflacije u tuzemstvu i inozemstvu.
6. Sustav puzećega raspona deviznoga tečaja – posebno istaknuti za navedeni tečaj upravo je razlika sa sustavom puzećega vezanja deviznog tečaja, gdje se razlika očituje u tome što je kod sustava puzećega raspona deviznog tečaja dopušten raspon tečajne fluktuacije u odnosu na paritet veći od 1 %.
7. Sustav upravljano–fluktuirajućega deviznog tečaja bez unaprijed obznanjenoga smjera tečaja. Navedeni tečaj osobit je po tome što monetarne vlasti dozvoljavaju fluktuaciju tečaja domaće valute prema unaprijed određenom rasponu. Također, kod navedenog tečaja javnosti nije poznat središnji tečaj koji služi kao osnovica za izračun raspona fluktuacije. Navedeni razlog omogućuje monetarnim vlastima potpunu diskreciju u vođenju politike deviznog tečaja.
8. Sustav slobodno-fluktuirajućeg deviznog tečaja – navedeni tečaj mijenja s sa promjenama ponude i potražnje na deviznom tržištu. Bitno za istaknuti da u okviru ovog sustava monetarne vlasti mogu intervenirati na deviznom tržištu s namjerom utjecaja na kretanje deviznog tečaja.

Osim prethodno gore navedenih vrsta deviznih tečajeva potrebno je napomenuti i moguće načine određivanja deviznih tečaja od kojih se ističu tri načina a to su: fiksni, fleksibilni (fluktuirajući), čisti fluktuirajući i kontrolirani (prljavi) tečaji. Svaki od ovih navedenih tečaja ima svoje prednosti i nedostatke. Tako je potrebno istaknuti da će zemlja koristiti onaj tečaj koji će najviše doprinositi njezinom gospodarskom rastu. Osim što bi odabir deviznog tečaja trebao biti usmjeren gospodarskom rastu, na njega također utječu i ostali čimbenici od kojih se ističu politički i institucionalni čimbenici. Teorija i praksa pokazale su da fiksne tečaje najčešće primjenjuju zemlje u razvoju gdje one svoju valutu vezuju za neki svjetski jaku valutu kao na primjer dolar ili euro, što im omogućava stabilnost cijena. S druge strane, zemlje koje uvode fleksibilni devizni tečaj obično se odlučuju za ciljanje inflacije (Krtalić i Benazić, 2010).

Fiksni devizni tečaj najčešće se javlja kod sustava valutnog odbora. Analize su pokazale kako fiksne devizne tečaje imaju manje zemlje koje su gospodarski i financijski siromašne. Također, uz navedeno može se reći kako su to gospodarstva slabije razvijenih demokratskih procedura, odnosno koji su skloni poštivanju određenih pravila. U pravilu fiksni tečajni režim najčešće imaju mala, otvorena gospodarstva koja su pogođena određenim šokovima i nerazvijenim tržištima.

S druge strane, fluktuirajući tečajni režimi javljaju se samo teorijski , dok se u praksi najčešće koristi upravljano fluktuiranje. Tako devizni tečaj čini instrument putem kojega se postižu određeni ciljevi monetarne politike, a koji se definiraju na primjer kroz stopu inflacije ili neke druge važnije gospodarske pokazatelje. Fluktuirajuće tečajne režime najčešće primjenjuju veća gospodarstva koja su uspješnija u upravljanju tečajnim kretanjima i koja su često izložena šokovima iz njihovog okruženja (Kordić, 2016).

Na kraju ovog potpoglavlja potrebno je naglasiti kako izbor deviznog tečaja ovisi o svakoj zemlji jer postoji široka lepeza vrsta deviznih tečaja. Dakle, potrebno je odabrati onaj devizni tečaj koji će voditi ostvarenju utemeljenih ciljeva ekonomske politike. Odabir tečaja ovisi o cjelokupnom gospodarskom stanju, pa tako devizni tečaji ne mogu biti jednaki za sve zemlje, ali isto tako oni su promjenjivi tijekom vremena. U daljnjem slijedu naglasak će biti na realnom efektivnom tečaju (u daljnjem slijedu rada REER).

3.2. Realni efektivni tečaj- pojam, definicija, izračun

Kako je realni efektivni tečaj jedna od analiziranih varijabli u našem modelu potrebno je prvenstveno objasniti kakav učinak stvara i kako se računa. Tako, realni efektivni tečaj predstavlja mjeru prosječnog trgovinskog vaganog tečaja valute prema košarici valuta koji je prilagođen razlikom u inflaciji u odnosu na druge zemlje. Osim REER-a potrebno je istaknuti nominalni efektivni tečaj (u daljnjem slijedu rada NEER) i njegovu vezu s REER-om. Dakle, NEER prema definiciji je mjera vrijednosti valute prema ponderiranom prosjeku nekoliko stranih valuta koje se mjere nominalnim dijelovima, odnosno koja ne uzima razlike između kupovne moći dvije zemlje. Za razliku od NEER-a, REER uključuje indekse cijena i njihove trendove. Možemo zaključiti prema navedenome sljedeće, REER je NEER je s uklonjenom inflacijom cijena ili troškova rada. (Macroeconomic Analysis, 2018)

Prema definiciji NEER predstavlja, odnosno omogućuje definiranje opsega u kojem se tečaj nacionalne valute promijenio u odnosu na tečaje zemalja trgovanja u odnosu na baznu godinu. Promjene NEER-a ne odražavaju promjene u kupovnoj moći valute, niti pokazuju u kojoj mjeri promijenjena konkurentnost dobara u zemlji i ne pokazuju izvozni potencijal tijekom određenog vremenskog razdoblja. REER se izračunava kako bi se odredio stupanj promjene kupovne moći valute tijekom određenog vremenskog razdoblja. REER se definira i kao prosjek bilateralnih tečajnih razlika između zemlje i svakog njezinog trgovinskog partnera. Realne efektivne tečajne liste koriste se za niz svrha kao što su procjena ravnoteže vrijednosti valute, promjena cijene ili troškovne konkurentnosti, pokretač trgovinskih tokova ili poticaji za proizvodnju preraspodijeljeni između sektora. Zbog značaja REER-a u ekonomskim istraživanjima i analizama politika, više institucija uključujući poznata tijela poput Svjetske banke, EUROSTAT-a, OECD itd., besplatno objavljuju različite REER pokazatelje i omogućuju njihovu analizu.

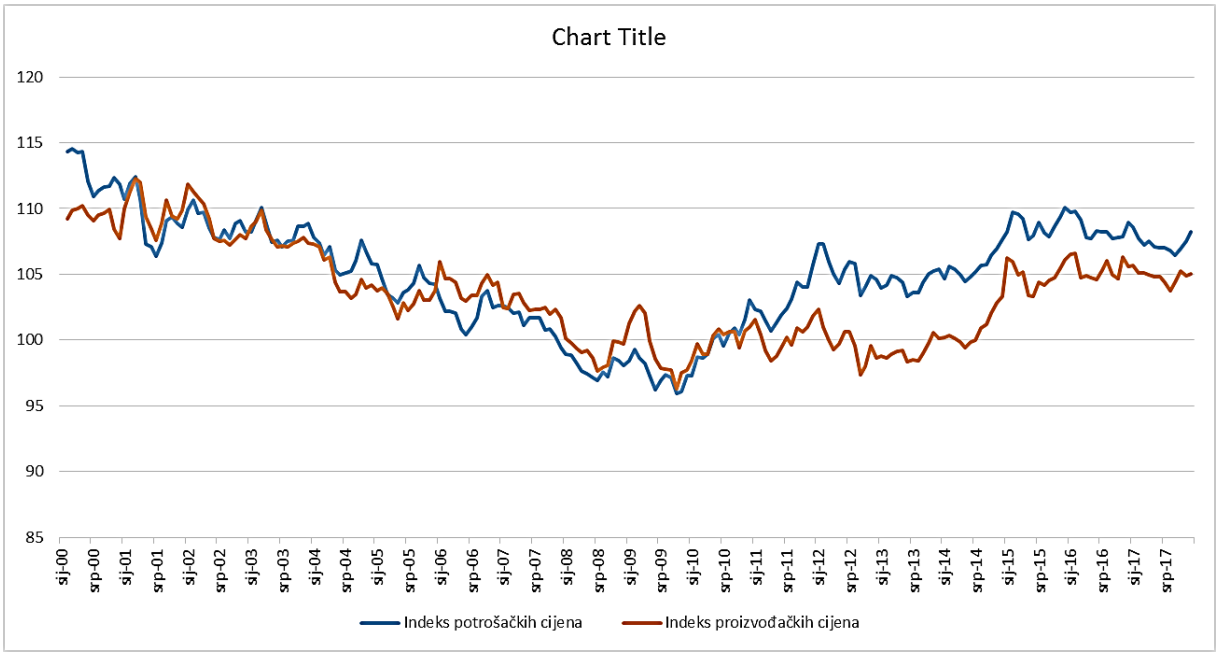
3.3. Tečajna politika Republike Hrvatske

Hrvatska koristi režim upravljano plivajućeg deviznog tečaja, gdje se tečaj određuje na deviznom tržištu. Intervencije na deviznom tržištu ima Hrvatska narodna banka (HNB). Nadalje, za hrvatsku monetarnu politiku možemo reći da postoji visoka razina euroizacije, te postojanje valutne klauzule u bankovnome poslovanju koja pred monetarnu i tečajnu politiku stavlja dodatne izazove i ograničava monetarni suverenitet. Možemo reći kako je euroizacija

posljedica mlade države i valute i kratkog vremena monetarne suverenosti koja je popraćena političkom nestabilnosti, tranzicijom ali i inflacijom (Kordić, 2016).

Kako HNB intervenira na deviznom tržištu, njezin primarni cilj je stabilnost cijena, odnosno stabilnost deviznog tečaja kune prema euru. Kako je na visoku razinu euroiziranosti sustava, razina cijena osjetljiva je na kretanje tečaja te se njihovom kontrolom ostvaruje i niska stopa inflacije. Daljnjim slijedom rada prikazan će biti grafički prikaz realnog efektivnog deviznog tečaja Republike Hrvatske za razdoblje od 2000. do 2017. godine.

Grafikon 2. Prikaz indeksa efektivnih tečajeva kune



Izvor: Izrada autora prema www.hnb.hr

Grafikon 2. prikazuje indekse efektivnih tečaja kune, odnosno indeks potrošačkih i proizvođačkih cijena. Razdoblje koje je analizirano na promatranom grafikonu je od 2000. pa do 2017. godine. Prije analize grafikona potrebno je navesti razliku između indeksa nominalnog i realnog efektivnog tečaja kune. Dakle, indeks nominalnoga efektivnog tečaja kune ponderirani je geometrijski prosjek indeksa bilateralnih nominalnih tečaja kune prema odabranim valutama glavnih trgovinskih partnera. Valute glavnih trgovinskih partnera i njihovi ponderi određeni su na osnovi strukture uvoza i izvoza robe prerađivačke industrije, pri čemu ponderi odražavaju izravnu uvoznu konkurenciju, izravnu izvoznu konkurenciju i izvoznu konkurenciju na trećim

tržištima. S druge strane, indeks realnoga efektivnog tečaja ponderirani je geometrijski prosjek indeksa bilateralnih tečaja kune korigiranih odgovarajućim indeksima relativnih cijena ili troškova. Indeksi nominalnih i realnih efektivnih tečaja kune izračunati su prema baznoj godini (2010. godina). Dakle, porast indeksa označava deprecijaciju kune prema košarici valute, dok pad indeksa označava aprecijaciju kune prema košarici valuta. Na temelju grafikona možemo zaključiti kako promatrani indeksi osciliraju tijekom vremena. Možemo zaključiti kako od početka promatranog razdoblja, dakle od 2000. pa sve do 2010. godine prisutna je bila aprecijacija kune, te je u srpnju 2008. godine bila najveća. Nakon toga, odnosno nakon 2010. godine pa do danas prisutna je deprecijacija kune koja je najveća bila u srpnju 2015. godine. Što se tiče deprecijacije ali i aprecijacije mjereno indeksom na bazi cijena proizvođača je blaža u odnosu na indeks na bazi cijena potrošača.

4. EMPIRIJSKA POZADINA

Sljedećim poglavljem bit će prikazana relevantna literatura, odnosno teorijska baza relevantnih radova na temu ovog diplomskog rada. Dakle, prikazat će se radovi koji su vezani za tematiku uvjeta razmjene, relativnog efektivnog tečaja i izvoznih i uvoznih cijena. Putem relevantnih studija prikazat će se empirijska istraživanja ali i činjenice vezane za istraživački dio. Prvo, kada se sagleda empirijska baza koja se odnosi na promjene cijena izvoza i uvoza, promjene u uvjetima trgovine i realnom efektivnom tečaju u Hrvatskoj nailazimo na relativno manji broj u odnosu na relevantnost teme. Daljnjim slijedom bit će prikazani domaći ali i strani autori koji su najznačajniji za empirijsku pozadinu navedenih varijabli.

Prvenstveno treba napomenutu radove u Hrvatskoj koji se bave ovom tematikom, odnosno koji su u središtu svoga istraživanja proučavali varijable kao što su izvozne i uvozne cijene, zatim uvjeti razmjene, odnosno prihodovni uvjeti razmjene, inflacija, tečaj i druge varijable, te pokušali utvrditi njihov učinak na cjelokupno gospodarstvo. Tako Šokčević (2008) analizira strukturu gospodarstva RH i dolazi do zaključka da se ne primjenjuje niti jedna ekonomska strategija koja se odražava na cjelokupno gospodarstvo. Autorica je došla do rezultata koji su pokazali da izvozni sektor nedovoljno pozitivno utječe na povećanje BDP-a, a uvozni sektor ima visoki negativan utjecaj. Izvozna propulzivnost robnog sektora RH je niska, a uvozna ovisnost je visoka i sve naglašenija, pa se područje ekonomskih odnosa Hrvatske s inozemstvom može ocijeniti negativnim sa stajališta gospodarskog rasta i razvitka. Nadalje, Botrić i Cota (2006) proučavaju inflaciju u Hrvatskoj tako da procjenjuju model otvorenog gospodarstva putem SVAR. Autori dolaze do zaključka kako je hrvatska inflacija snažno vezana uz šokove u uvjetima razmjene i bilanci plaćanja. Rezultati također ukazuju na to da monetarni šokovi imaju relativno mali utjecaj na inflaciju u Hrvatskoj. Uz sve navedeno treba naglasiti da uvjeti razmjene imaju snažan utjecaj na generiranje inflacije gdje se naglašava nesposobnost hrvatskog gospodarstva da se razvije u konkurentniju ekonomsku strukturu koja će efikasno nastupati na međunarodnom tržištu.

Kako je uvjete razmjene moguće proučavati kao indeks izvoznih i uvoznih cijena, ali i gdje je moguće prikazati njihovu vezu s gospodarskim rastom nailazimo na sljedeće relevantne radove. Tako, Tomić (2012) analizira važnost uvjeta razmjene u RH. Autor dolazi do zaključka kako prihodovni uvjeti razmjene imaju visoku značajnost za gospodarstvo Hrvatske, odnosno kako

je Hrvatska malo otvoreno gospodarstvo te iz toga razloga međunarodna razmjena ima važnu ulogu za njezin napredak. Osim navedenog, autor analizira učinke pozitivne/negativne na gospodarski rast i napredak. Nadalje, Škare, Šimurina i Tomić (2012) su usko povezani s prethodnim radom. Dakle, autori proučavaju uvjete razmjene i njihovu fluktuaciju tj. utjecaj na cijelo gospodarstvo. Autori su došli do zaključka kako su uvjeti razmjene relativno stabilni sugerirajući kako fluktuacije nisu imale značajan efekt na perspektivu rasta gospodarstva Hrvatske. Također, naglašavaju kako uvjeti razmjene ovise o makroekonomskoj politici, odnosno da se u Hrvatskoj uvjeti razmjene ponajviše odražavaju putem povećanja volumena izvoza.

Dalje, važan doprinos su ostavili i Tica i Posedel (2009) koji su pokušali procijeniti prolazni učinak u Hrvatskoj pomoću TAR modela koji su popularni u nelinearnim vremenskim serijama i koji su specifični zbog toga što mogu odrediti, procijeniti i protumačiti vezu s ostalim nelinearnim vremenskim modelima. Autori su došli do zaključka da mjesečne promjene nominalnog tečaja njemačke marke i načina na koji nominalni tečaj utječe na inflaciju je asimetričan. Znači iznad određenog praga utjecaj promjene nominalnog tečaja na inflaciju je bio statistički značajan, dok ispod razine praga bio je statistički neznačajan. S druge strane zanimljiv je i rad koji je učinio Bobić (2010) koji se u svom radu bavio procjenom cjenovnih i dohodovnih elastičnosti hrvatskih trgovinskih tokova i to za razdoblje nakon što je Hrvatska pristupila WTO-u 2000. i do 2007. godine. Rezultati analize pokazali su da je osjetljivost u izvoznim i uvoznim cijenama relativno niska, dok su dohodovni učinci bili jači.

Osim spomenutih autora važan doprinos što se tiče uvjeta razmjene, odnosno utjecaj izvoza na gospodarstvo hrvatske prisutan je kod Tomića (2014). Autor analizira da li izvoz ima važan utjecaj na gospodarski rast Hrvatske, odnosno da li volumen izvoza ima širi efekt poput efekta kroz rast produktivnosti. Autor dolazi do zaključka kako izvozna perspektiva ima značajnu ulogu pogotovo za mala otvorena gospodarstva u razvoju upravo kao što je Hrvatska. Uz navedeno autor dolazi i do zaključka kako izvozni sektor nedovoljno pozitivno utječe na povećanje bruto domaćeg proizvoda, odnosno da uvozni sektor ima visoki negativni učinak. Visoka izvozna koncentracija primarnih dobara koji nemaju veliku dodatnu vrijednost vodi velikoj volatilnosti u izvoznim prihodima i ukupnom gospodarskom rastu, smanjuje rast produktivnosti i pogoršava prihodovne uvjete razmjene. Svim navedenim činjenicama dolazi se do konačnog zaključka kako Hrvatska mora provoditi aktivniju izvoznu politiku.

Nadalje, važan aspekt proučavanja su upravo izvozne i uvozne cijene i njihov utjecaj na gospodarski rast. Tako Šimurina i Tomić (2012) analiziraju efekte uvjeta razmjene u Hrvatskoj za razdoblje 1997.- 2010. godine, odnosno pokušali su objasniti kako promjene izvoznih i uvoznih cijena imaju utjecaj na realni dohodak građana ali i kakve je koristi gospodarstvo ostvarilo tim promjenama. Autori dolaze do zaključka kako kretanje BDD ima pozitivan trend u odnosu na kretanje realnog BDP-a, odnosno da realni BDP podcjenjuje rast realnog dohotka građana do kojeg dolazi povećanjem uvjeta razmjene. Također, autori su došli i do zaključaka kako povećanje u realnom BDP-u ali i u realnom dohotku su odraz pozitivnih tijekova uvjeta razmjene.

Prethodno spomenuti radovi bazirali su se na uvjetima razmjene, izvoznim i uvoznim cijenama te kakav efekt stvaraju na gospodarski rast. Daljnjim slijedom prikaza empirijske baze prikazani će biti radovi s tematikom izvoza i uvoza, odnosno vanjskotrgovinskom bilancom. Tako, možemo izdvojiti autore koji su se najviše istaknuli u ovom dijelu proučavanja: Turčić (2015), Kovač (2012), Buturac (2009), Tica (2012) i Marić (2012) U daljnjem tekstu prikazat će se do kojih su zaključaka došli pojedini spomenuti autori.

Tako Turčić (2015) istražuje vanjskotrgovinsku politiku Hrvatske, mjere i instrumente. Istražuje povezanost deviznog tečaja i vanjskotrgovinske razmjene, odnosno sagledava međunarodnu razmjenu Republike Hrvatske. Autor dolazi do zaključka da je problem vanjskotrgovinske politike RH usitnjenost hrvatskih gospodarstava, nedostatni proizvodni kapaciteti, nejasne izvozne strategije itd. Smatra da treba jačati konkurentnost hrvatskog gospodarstva, a sa time i jačanje izvoza kao strateškog opredjeljenja. Nadalje, autor dolazi do zaključka da postupnom devalvacijom kune u odnosu na euro, izvozno orijentirani gospodarstvenici su dobili poticaj, a što se očituje u značajnom smanjenju deficita bilance robe, unatoč brojnim poteškoćama u RH.

Nadalje Kovač (2012) istražuje utjecaj međunarodne razmjene, odnosno kako izvoz utječe na rast BDP-a u RH za razdoblje od 2001.-2010. godine. Analiziran je utjecaj izvoza robe na realni rast BDP-a. Rezultati su pokazali da izvoz robe ima najmanje pozitivan doprinos stopi rasta BDP-a. Autori navode da se rast i razvoj hrvatskog gospodarstva ne može povećati samo kroz izvoz već treba važnost pridati izvozu s visokom dodanom vrijednošću. Također, autori dolaze do zaključka da u promatranom razdoblju Hrvatska ima nisku razinu izvoza robe (posebice industrije), te da postoji mala pokrivenost uvoza izvozom. Kao uzrok slabe konkurentnosti

hrvatske međunarodne razmjene autori navode: usitnjenost proizvodnje, nedovoljna vertikalna i horizontalna povezanost poslovnih subjekata, slab tehnološki razvoj i tako dalje. Na prethodno prikazane rezultate provedenog istraživanja možemo napraviti poveznicu s Buturac (2009) koji analizira strukturne karakteristike izvoza i uvoza hrvatskog gospodarstva u razdoblju tranzicije. Autor zaključuje kako Hrvatska nije iskoristila ekonomsku integraciju za rast izvoza. Rezultati analize pokazuju da proizvodi s komparativnim prednostima ne ostvaruju višu dodanu vrijednost, nego prevladava međusektorska trgovina, a što se tiče uvoza došlo je do kontinuiranog rasta kineskih proizvoda.

Osim navedenih autora treba napomenuti i radove Tica (2012) i Marić (2012), gdje Tica (2012) koji ističe kako je upravo rast kvalitete, a ne kvantitete izvoznih proizvoda u uspješnim tranzicijskim zemljama bio najuvjerljivije objašnjenje visokog stupnja korelacije između održivosti tekućeg računa platne bilance i snažne aprecijacije realnog tečaja. Autor zaključuje da u stvarnosti većina tržišta nije niti savršena niti nesavršena, ali su karakterizirana malim brojem poduzeća uključenih u stratešku igru na tržištu. Unatoč tome, većina ekonomskih teorija bazira se na pretpostavkama gdje poduzeća egzistiraju kao price-takeri u savršenoj konkurenciji ili price-setteri u klasičnoj monopolskoj konkurenciji. S druge strane Marić (2012) analizira utjecaj politike deviznog tečaja na promjenu strukture bosanskohercegovačkog gospodarstva od uvozno ovisne u izvozno orijentiranu privredu. Autor dolazi do zaključka kako bi se postigla unutarnja i vanjska ravnoteža koristi se upravo currency board, uz prilagođavanje realnog deviznog tečaja, odnosno eliminiranje glavnog uzroka precijenjenosti tečaja domaće valute a to je nedovoljna međunarodna konkurentnost. Takvi uvjeti precijenjenosti domaće valute dovesti će do smanjenja investitora jer je racionalno ponašanje investitora ulaganje u valute koje su podcijenjene, a ne precijenjene.

Analogno s prethodnom teorijskom pozadinom u slijedu rada prikazat će se radovi iste problematike, no sa stranim autorima. Kako je prethodno već napomenuto, literatura vezana za ovu problematiku je u Hrvatskoj dosta slabo istražena nego li u ostatku svijeta. Tako, možemo istaknuti autore koji su najznačajniji po svojim istraživanjima, a koja su vezana za uvjete razmjene, prolazni učinak, izvoz uvoz i tako dalje. Na početku ćemo istaknuti Billmeire i Bonato (2004) koji su primijenili dvije različite metode za procjenu prolaznog učinka, a to su bile metode rekurzivni i kointegrirani VAR. Autori su došli do zaključka da je Hrvatska bila visoko dolarizirana ekonomija, te je prolazni učinak nizak nakon ekonomske stabilizacije 2000-tih godina. Od posebne važnosti upravo je Gutmann (1981) koji sagledava metode koje

definiraju i kvantificiraju učinke na bruto domaći proizvod. Autor u radu uspoređuje efekte uvjeta razmjene između zemalja OECD-a koji se odražavaju u pogoršanju uvjeta razmjene i promjenama u relativnim cijenama kod zemalja. Autor dolazi do zaključka da velike promjene u relativnim cijenama između uvoza i izvoza domaće ekonomije mogu generirati različite rezultate s klasičnim makroekonomskim mjerama. Na primjer, mora se naglasiti kako povećanje deflatora cijena ne predstavlja odgovarajući pokazatelj inflacije u mjeri u kojoj se može znatno razlikovati od porasta domaće razine cijena, samo zbog velikog porasta uvoznih cijena.

Nadalje, potrebno je istaknuti i Balassa (1985) koji proučava interese razvijenih i nerazvijenih zemalja u liberalizaciji međunarodne trgovine gdje dolazi do zaključka kako postoje određene asimetrije između razvijenih zemalja i zemalja u razvoju ističući kako zemlje u razvoju troše devizne zarade na robu uvezenu iz razvijenih zemalja. Također, važan doprinos je i autora Diewerta i Lawrence (2006) koji analiziraju uvjete razmjene Australije i dolaze do zaključka ako produktivnost raste, porast uvoznih cijena u odnosu na uvozne cijene dopušta veću količinu uvoza, koja će se kupiti za određenu količinu izvoza što će rezultirati povećanjem kupovne moći. S druge strane sličan doprinos je autora Majeed i Affat (2014) koji istražuju povezanost izvoza, uvoza i gospodarskog rasta u Saudijskoj Arabiji. Rezultati su pokazali značajnu vezu između izvoza i uvoza, dok rezultati između izvoza i gospodarskog rasta kao i uvoza i gospodarskog rasta bili su statistički neznačajni. Ostala zanimljiva istraživanja na ovu problematiku jesu: Liu i Chen (2017), Choudhri i Hakura (2012), Corrigan (2005) i Jabara (2009).

Tako Corrigan (2005) analizira vezu između uvoznih cijena i inflacije u SAD-u. Autor ističe kako uvozne cijene imaju sve značajniju ulogu za gospodarstvo. Uz navedeno, rezultati analize sugeriraju da kreatori ekonomske politike moraju biti svjesni trendova uvoznih cijena. Nadalje, Jabara (2009) istražuje utjecaj realnog efektivnog tečaja na uvozne cijene. Autor dolazi do zaključka da promjene u dolaru utječu na cijene robe u međunarodnoj trgovini, te uz navedeno rezultati analize sugeriraju slab utjecaj tečaja na uvozne cijene. Uz navedena istraživanja važno je napomenuti i istraživanje Goldsteina i Khana (1985). Autori u svom istraživanju procjenjuju kako manje i otvorene ekonomije baziraju svoje izvozne cijene na cijenama konkurenata na svjetskom tržištu, dok velike i manje otvorene ekonomije određuju svoju razinu cijena na temelju domaćih faktora proizvodnje.

Kako važan dio ovog rada čine uvjeti razmjene potrebno je istaknuti kako mnogi autori očekuju negativan utjecaj volatilnosti uvjeta razmjene na gospodarsku aktivnost ali i na udio izvoza u ukupnom bruto domaćem proizvodu. Tako Berden (2006) naglašava kako je moguće da povećana volatilnost utječe na smanjenje očekivanih stopa rasta gospodarstva time da efekt neizvjesnosti nedvojbeno determinira financijske odluke Vlade, proizvođača i kućanstva. Autor dolazi do zaključka da volatilnost uvjeta razmjene može imati negativan efekt i na razinu otvorenosti gospodarstva.

Osim uvjeta razmjene od važnog značaja su i uvozne i izvozne cijene, pa tako Diewert i Morrison (1986) analiziraju izvozne i uvozne cijene. Autori dolaze do zaključka kako porast relativnih cijena izvoza u odnosu na uvozne cijene ima isti efekt kao povećanje ukupne faktorske produktivnosti. Autori naglašavaju kako povećanje uvjeta razmjene omogućuje svakoj zemlji povećanje domaćeg proizvoda pri zadanim razinama inputa. S druge strane, smanjenje uvjeta razmjene smanjuje neto količinu dobara koju zemlja ostvaruje pri zadanoj razini inputa.

Od ostalih zanimljivih istraživanja ističu se Birdsall i Hamoudi (2002) i Chen, Li i San (2010). Tako Birdsall i Hamoudi (2002) analiziraju utjecaj uvjeta razmjene na BDP. Autori dolaze do zaključka kako zatvorene zemlje ponajprije ovise o primarnim robama, te da trgovinska politika može imati utjecaj za diversifikaciju robe uz pretpostavku povoljnog tečaja i privlačenja izravnih inozemnih ulaganja. Na kraju Chen, Li i San (2010) analiziraju rast Istočne Kine. Analiza rezultata pokazala je da ukupan izvoz i uvoz utječu na rast Istočne Kine. Rezultati pokazuju dugoročnu vezu između uvoza i izvoza na rast BDP-a.

5. ANALIZA EKONOMETRIJSKOG MODELA

Naredno poglavlje predstavlja srž ovoga rada iz razloga što će ovim poglavljem biti prikazano do kojih se je zaključaka došlo analizom promatranih varijabli. Prvenstveno treba napomenuti kako su za izradu modela korištene varijable izvozne cijene (lnPex), uvozne cijene (lnPim), realni efektivni tečaj (lnREER) te prihodovni uvjeti razmjene (lnITOT). Navedene varijable će detaljnije biti objašnjene u daljnjem slijedu rada. Ekonometrijska analiza na promatranim varijablama prikazana je za Republiku Hrvatsku. Vremenska serija podataka je od 2000 Q1 do 2017 Q2. Izrada modela rađena je prema Johansenovoj metodologiji za dugi rok, te uvjetni VEC model za kratki rok. Također potrebno je napomenutu kako ekonomska i ekonometrijska literatura sugeriraju da odnos između uvjeta razmjene i ostalih varijabli može najbolje objasniti vektorskim modelima vremenskih nizova. Osim toga primarni cilj ovog rada je procijeniti kako promjene u uvjetima razmjene i tečaju utječu na cijene hrvatskog izvoza i uvoza .

5.1. Metodološki pristup

Metodološki pristup modela rađen je prema Johansenovoj metodologiji (Johansen, 2002) za dugi rok i uvjetni VEC model (parsimonious vector error correction model) za kratki rok. Budući da želimo procijeniti kratkoročne i dugoročne implikacije koristiti ćemo vektorsku autoregresiju tj. VAR (vector autoregressive model). Također potrebno je odrediti i izbor reda VAR-a što znači da o redu VAR-a ovisi ponašanje funkcija odgovora na impuls kao i dekompozicija varijance prognostičkih grešaka te se moramo rukovoditi određenim kriterijima pri izboru reda VAR-a. Uobičajena su četiri testa za testiranje reda VAR-a: final prediciton error criterion (FPE), Akaike (AIC), Hannan i Quinn (HQ) i Schwarz (SC). U daljnjem slijedu rada biti će na primjeru modela prikazan odabir reda VAR-a. S druge strane, za odabir kointegracijskog ranga koristi se Johansenov test prema kojemu vidimo koliko dugoročnih veza postoji između promatranih varijabli.

Kako je prethodno navedeno da će se prilikom izrade modela koristiti Johansenova metodologija i uvjetni VEC model potrebno je detaljnije objasniti navedene pristupe. Naime, u cilju proučavanja dugoročne ravnoteže između promatranih varijabli u modelu proučavati će se rezultati Johansenove kointegracije. VEC model smatra se jednim od najpoznatijih i naviše upotrebljivih modela analize povezanosti. Zatim važno za navesti je da isti omogućuje i grafičke prikaze impulsnih funkcija kao i prikaz dekompozicije varijance ali također i široke spektar

testova koji pokazuju kvalitetu modela. Kointegriranost varijabli upućuje na postojanje dugoročne linearne veze između varijabli, dok ukoliko se procesi pokažu nestacionarnim tada se mora testirati moguća kointegracija između njih. Osim toga, broj nezavisnih kointegracijskih vektora određenog kointegracijskog procesa zove se kointegracijski rang. Važna napomena je sljedeća da broj nezavisnih kointegracijskih vektora može biti i više. Najznačajnije kod analize kointegracije je upravo utvrđivanje ranga dugoročne matrice π modela. Prema formuli matrica π reda je n*n, odnosno maksimalni mogući rang je nula. U tom slučaju matrica π sadrži nula elemente i kratkoročni elementi ne zavise o elementima u razinama vektora zt. S druge strane, rast varijabli vektora zt zavisi samo o pomaknutim promjenama svih varijabli. Potrebno je još objasniti i α i β koeficijente koji će biti prikazani u kointegraciji. Prema definiciji β predstavlja kointegracijski vektor, dok je α matrica koeficijenata kointegracijskog vektora i predstavlja brzinu prilagodbe dugoročnoj ravnoteži (Johansen, 2002).

Kada se provede postupak odabira kointegracijskog ranga pomoću Johansenove metodologije omogućuje se testiranje hipoteza o povezanosti između varijabli u dugom roku. Moguće je testirati ograničenja na parametre kointegracijskih relacija matrice β ili na parametre matrice α. Ograničenja nad matricom β predstavljaju nultu hipotezu na pojedinim parametrima, dok ograničenja kod α matrice predstavljaju problematiku slabo egzogene varijable koja ne dovodi do ostvarivanja dugoročne ravnoteže. Kako u ovom radu za izradu modela imamo veći broj varijabli moguće je i definiranje više kointegracijskih vektora. Ukoliko postoji više kointegracijskih vektora potrebno je definirati određena ograničenja na α i na β parametrima. Pojam slabe egzogene varijable je upravo vezan za uvjetni VEC model koji će slijedom rada biti detaljnije i objašnjen (Tomić, 2012).

Slabo egzogena varijabla je ona varijabla koja ne sadrži dodatne informacije za procjenu parametara, odnosno ona koja nema značajnu ulogu kod dugoročne ravnoteže. U VEC modelu, slabo egzogena varijabla je varijabla koja ostaje u jednadžbi dugoročne dinamike i u kratkoročnoj dinamici ostalih varijabli ali se njezina kratkoročna dinamika ne analizira. Također kod slabo egzogene varijable analizira se i tzv. parcijalni VEC model (parsimonious VEC model). Navedeni model često se zove i uvjetni model iz razloga jer predstavlja slabu egzogenost varijabli. Parcijalni VEC model koristi se u situacijama kada model zahtijeva drugačiju normalizaciju vektora u β matrici. Slabo egzogena varijabla u tim modelima preuzima odgovornost za probleme u opisu modela, te time uvjetni VEC model omogućuje promatranje kratkoročne dinamike. Zatim, kvaliteta modela može se testirati putem dostupnih testova koji

trebaju dokazati da je model stabilan i da se mogu donijeti relevantni zaključci (Jacobs i Wallis, 2010).

5.2. Stupanj integriranost vremenski serija

Promatranje vremenskih serija podataka temelji se na analizi stacionarnosti procesa. Kako varijable modela u našem istraživanju pokazuju određeni trend rasta, to sugerira da li se radi o stohastičkom ili determinističkom trendu. Tako ćemo testiranjem testova jediničnog korijena utvrditi kojeg su reda promatrane varijable. Od testova jediničnih korijena koji će slijedom rada biti prikazani jesu: prošireni Dickey- Fullerov test (ADF), Phillips – Perron test (PP) i Kwiatkowski – Phillips – Schmidt – Shinov test (KPSS). Navedeni testovi su testovi integriranosti vremenske serije.

Kako varijable u modelu pokazuju određeni trend rasta, prva vrsta testova koju koristimo je ona s konstantom, odnosno konstantom i linearnim trendom kao deterministički članovima na varijablama u razini. Tako testiramo da li je varijabla trend stacionarna ili diferentno stacionarna. Druga vrsta testova odnosi se na testiranje stacionarnosti vremenskih serija u prvoj diferenciji, odnosno da je prva diferencija varijable I (0) proces, u kojem slučaju možemo odbaciti hipotezu da je varijabla u razini I (2) proces s višestrukim jediničnim korijenom, koji onda ne možemo stacionirati putem samo jedne diferencije. U daljnjem slijedu rada biti će prikazani rezultati jediničnih testova.

Tablica 1. Testiranje jediničnih korijena

Augmented Dickey-Fuller test (ADF)				
Varijable	**U razinama**		**U prvoj diferenciji**	
	konstanta	*konstanta + trend*	*konstanta*	*konstanta + trend*
lnPex	- 2,23	- 0,68	- 5,52 ***	- 5,65 ***
lnPim	- 2,15	- 2,61	- 6,21 ***	- 6,22 ***
lnREER	- 0,46	- 1,63	- 6,25 ***	- 6,32 ***
lnITOT	- 2,46	- 2,35	- 8,06 ***	- 7,98 ***
Phillips-Perron Unit Root test (PP)				
Varijable	**U razinama**		**U prvoj diferenciji**	
	konstanta	*konstanta + trend*	*konstanta*	*konstanta + trend*
lnPex	- 2,09	- 0,67	- 8,11 ***	- 8,55 ***
lnPim	- 2,22	- 2,12	- 5,25 ***	- 5,42 ***
lnREER	- 0,55	- 1,56	- 4,34 ***	- 4,27 ***
lnITOT	- 2,13	- 2,22	- 7,06 ***	- 6,98 ***

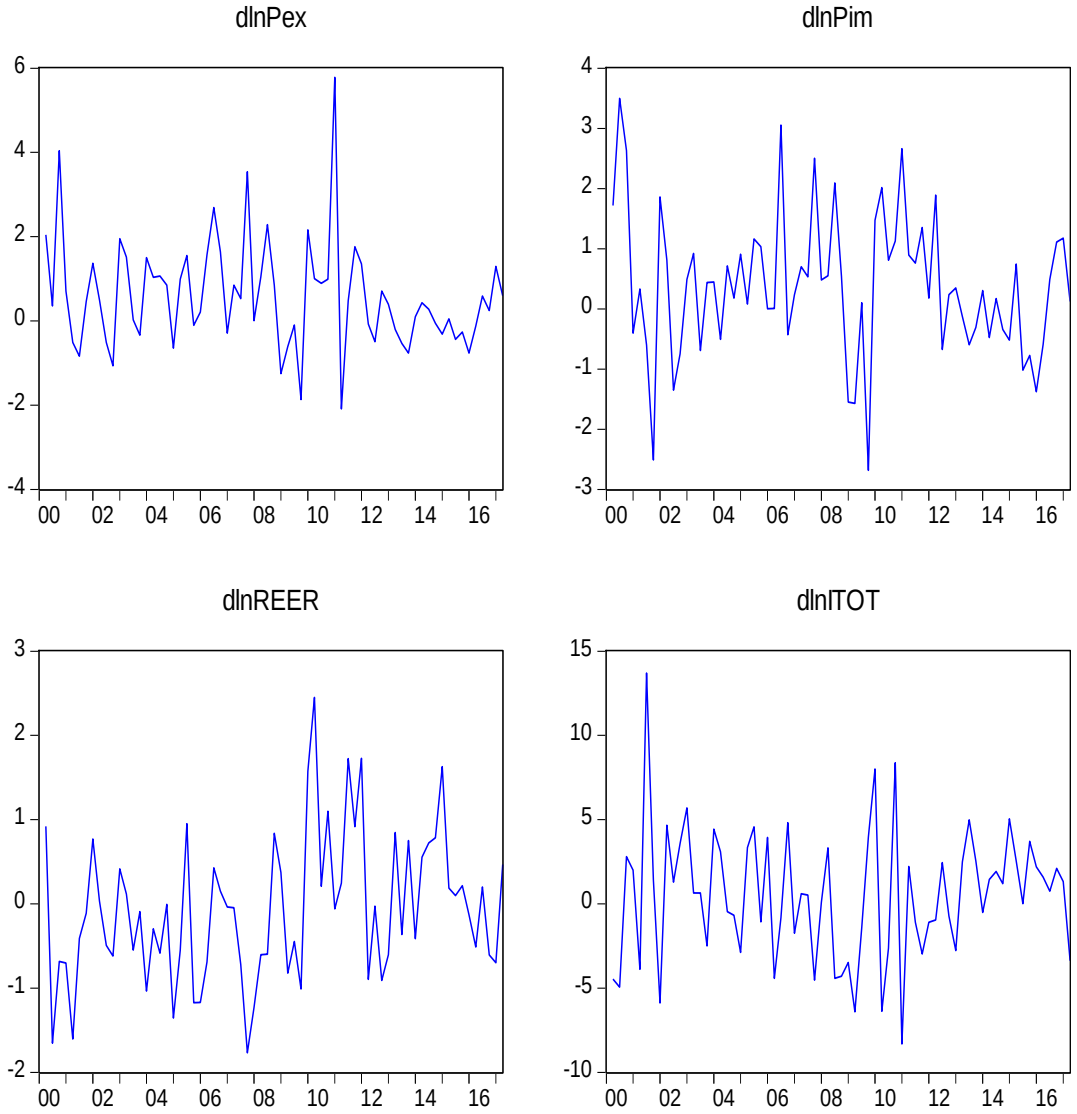
Kwiatkowski-Phillips-Schmidt-Shin Unit Root test (KPSS)				
Varijable	**U razinama**		**U prvoj diferenciji**	
	konstanta	*konstanta + trend*	*konstanta*	*konstanta + trend*
lnPex	0,73 **	0,15 **	0,13	0,12
lnPim	0,76 ***	0,08	0,05	0,05
lnREER	0,55**	0,08	0,04	0,04
lnITOT	0,70 **	0,10	0,07	0,07

- ***, **, * *predstavljaju 1%, 5% i 10% razinu značajnosti*

Izvor: Izračun autora (EViews 9.5).

Tablica prikazuje testove jediničnih korijena (prošireni ADF test, PP test i KPSS test) u razinama i u prvoj diferenciji sa konstantom i sa konstantom i trendom. Možemo zaključiti, kako varijable nisu trend stacionarni procesi jer ne možemo odbaciti hipotezu o postojanju jediničnog korijena procesa u razini i s trendom. Možemo odbaciti hipotezu jer svi testovi odbacuju hipotezu na visokim razinama značajnosti (1%, 5% i 10% značajnosti). Ukoliko bi se radilo o trend stacionarnim varijablama, proces ne bi mogli stacionirati diferenciranjem. Nakon toga možemo testirati radi li se možda o diferentno stacionarnim procesima. Nakon što su varijable diferencirane postignuta je stacionarnost, što nam ukazuje da se radi o I (1) procesima. Analizom testova, procese smo uspjeli stacionirati putem prve diferencije. Nadalje, možemo zaključit da hipotezu o postojanju jediničnog korijena procesa u prvoj diferenciji možemo odbaciti sa statističkom značajnošću od 1%, odnosno 99% pouzdanošću možemo zaključiti da su sve analizirane varijable I (1) procesi. U daljnjem slijedu rada prikazati će se varijable modela u prvoj diferenciji.

Grafikon 3. Varijable u prvoj diferenciji



Izvor. Izrada autora (EViews 9.5).

Grafikon prikazuje varijable modela (dlnPex, dlnPim, dlnREER i dln ITOT) u prvim diferencijama. Grafički prikaz kao i provedeni testovi jediničnog korijena sugeriraju stacionarnost već u prvoj diferenciji. Kako smo utvrdili da su sve varijable istog reda, stvorili smo preduvjet za analizu kointegracije u dugom roku, te uvjetnog VEC modela za kratkoročnu dinamiku.

U sladu s prethodnim teorijskim objašnjenjem možemo se osvrnuti na model ovoga rada. Empirijski model koji se koristi za procjenu odnosa izvoznih i uvoznih cijena, uvjeta razmjene i tečaja temelji se na njihovom međusobnom djelovanju. Metodološki okvir analize modela u ovom radu može se prikazati sljedećim dvjema formulama koje su:

$$Pex = Pim + EXC + TOT$$

$$Pim = Pex + EXC + TOT$$

Iz gore navedenih jednadžbi Pex predstavlja izvozne cijene na koje utječu promjene uvoznih cijena (Pim), tečaj (EXC) i uvjeti razmjene (TOT). S druge strane, slično prvoj jednadžbi, druga predstavlja sljedeće: na uvozne cijene utječu izvozne cijene, tečaj i uvjeti razmjene. Nadalje, iz gore navedenih jednadžbi možemo izvesti sljedeći dugoročni empirijski model koji je određen kao:

$$\boldsymbol{lnPex_t = \beta_{10} + \beta_{11}\, lnPim_t + \beta_{12}\, lnREER_t + \beta_{13}\, lnITOT_t + \varepsilon_{1,t}}$$

$$\boldsymbol{lnPim_t = \beta_{20} + \beta_{21}\, lnPex_t + \beta_{22}\, lnREER_t + \beta_{23}\, lnITOT_t + \varepsilon_{2,t}}$$

Kako bismo procijenili kratkoročnu dinamiku, moramo procijeniti VEC model na istim ali sada diferenciranim zavisnim varijablama pomoću reduciranog oblika (uvjetni VEC model), te također s diferenciranim nezavisnim varijablama sa odstupanjem t=j, j=1,2,3,4 koristeći kvartalne podatke. Uz prethodno navedene pretpostavke također mora postojati i t-1 odstupanje iz glavne kointegracijske veze. Budući da su sve varijable u glavnim modelima I (0), statistički zaključci pomoću t i F testa su valjani. Prema definiranim formulama možemo zaključiti kako će uvozne cijene, realni efektivni tečaj i prihodovni uvjeti razmjene pozitivno utjecati na izvozne cijene, ali također kada se sagleda druga jednadžba isto izvozne cijene, realni efektivni tečaj i prihodovni uvjeti razmjene utječu pozitivno, no u ovom slučaju na uvozne cijene. Uvjetni VEC model koristi se jer je drugačija restrikcija α učinila model restriktivnim te nismo mogli analizirati funkcije impulsnog odaziva i dekompoziciju varijance za sve varijable ali i zato što je odabrano odstupanje u dugom roku uklonjeno unutar tumačenja kratkog roka, odnosno nije bilo moguće tumačiti i Grangerovu uzročnost. Na takav način reducirani oblik VEC modela predstavlja alternativni put koji može objasniti kratki rok. Daljnjim slijedom rada prikazano će biti odabir lagova i kointegracijskog ranga modela sa dostupnim izračunima, te prikaz podataka i opis varijabli koji su korišteni za analizu ovoga rada.

5.3. Podaci

U ovome radu prikazuje se analiza odabranih pokazatelja za Republiku Hrvatsku za razdoblje od 2000. do 2017. godine. Analiza se temelji na kvartalnim podacima za razdoblje 2000: Q1-2017: Q2 za varijable izvozne i uvozne cijene, tečaja i prihodovnih uvjeta razmjene. Analiza obuhvaća široko vremensko razdoblje i važno je za napomenuti da podaci prikazuju kretanje varijabli prije i polije krize, odnosno vidjeti će se kako je kriza utjecala na njihov smjer (smanjenje ili povećanje). Prvenstveno, sve varijable su sezonski prilagođene korištenjem Census X13 postupka sezonske prilagodbe i zatim transformirane u njihovu logaritamsku formu zbog izrade modela. Razlog korištenja procesa desezoniranja je upravo taj što vremenske serije podataka koje se promatraju na primjer na kvartalnoj ili mjesečnoj razini najčešće sadrže ciklička kretanja. Zato se koristi proces desezoniranja koji uklanja ciklička sezonska kretanja i definira trend kao komponentu tih serija. Nadalje, što se tiče logaritamske transformacije ona se koristi kako bi se osigurala stabilizacija varijance ali i normalizacija kod varijabli koje imaju asimetričnu distribuciju. Što se tiče prikupljanja podataka, podaci su preuzeti sa Hrvatske narodne banke (HNB) i sa Državnog zavoda za statistiku (DZS). Sljedeća važna napomena kako prikazuje tablica 2. u slijedu rada, je da izvozne cijene kako je prethodno napomenuto da su logaritmirane i desezonirane ali također da izvozne cijene prikazuju izvozne cijene dobara s baznom godinom 2010. Nadalje, isto se odnosi i na ostale varijable modela, pa tako uvozne cijene predstavljaju uvozne cijene dobara i zatim prihodovni uvjeti razmjene koji predstavljaju prihodovne uvjete razmjene dobara. Dok s druge strane, realni efektivni tečaj predstavlja indeks realnog efektivnog deviznog tečaja.

Dakle, naša analiza temelji se na varijablama **lnPex** kao izvozne cijene i **lnPim** kao uvozne cijene. Do navedenih varijabli došli smo izračunom na sljedeći način: cijenu izvoza izračunali smo dijeljenjem nominalnih vrijednosti izvoza dobara i usluga sa realnim vrijednostima izvozom dobara i usluga. S druge strane, na isti način smo izračunali i cijenu uvoza samo što se kod cijene uvoza u izračun uzima uvoz dobara i usluga. Drugo, umjesto klasičnih uvjeta razmjene u ovom radu koriste se prihodovni uvjeti razmjene za dobra iz razloga što se navedena varijabla smatra relevantnijom u makroekonomskom modeliranju. Stoga se naša analiza temelji na **lnITOT** kao prihodovni uvjeti razmjene koji se temelje na podacima nacionalnih računa o nominalnom i realnom izvozu i uvozu u kunama. Izračunavaju se množenjem uvjeta razmjene (izvozne cijene / uvozne cijene) sa volumenom izvoza. Viši, odnosno niži omjer podrazumijeva poboljšanje ili pogoršanje u prihodovnim uvjetima razmjene. Posljednju varijablu modala čini

realni efektivni tečaj tzv. **lnREER** koji je deflacioniran indeksom potrošačkih cijena. Povećanje ukazuje na realnu deprecijaciju dok smanjenje predstavlja realnu aprecijaciju tečaja. S obzirom na činjenicu da se izravna i točnija procjena temelji na proizvođačevoj cijeni (PCP metoda) ili na određivanju cijena lokalne valute (LPC metoda), to najčešće zahtijeva drugačije metodološke pristupe.

Tablica 2. Popis varijabli

Varijabla	Oznaka	Definicija
Izvozne cijene	**lnPex**	Prirodni logaritam izvoznih cijena dobara (2010=100)
Uvozne cijene	**lnPim**	Prirodni logaritam uvoznih cijena dobara (2010=100)
Realni efektivni devizni tečaj	**lnREER**	Prirodni logaritam indeksa realnog efektivnog deviznog tečaja (2010=100)
Prihodovni uvjeti razmjene	**lnITOT**	Prirodni logaritam prihodovnih uvjeta razmjene dobara (2010=100)

Izvor: Izrada autora

** sve varijable su prethodno dezesonirane X-13 ARIMA metodom*

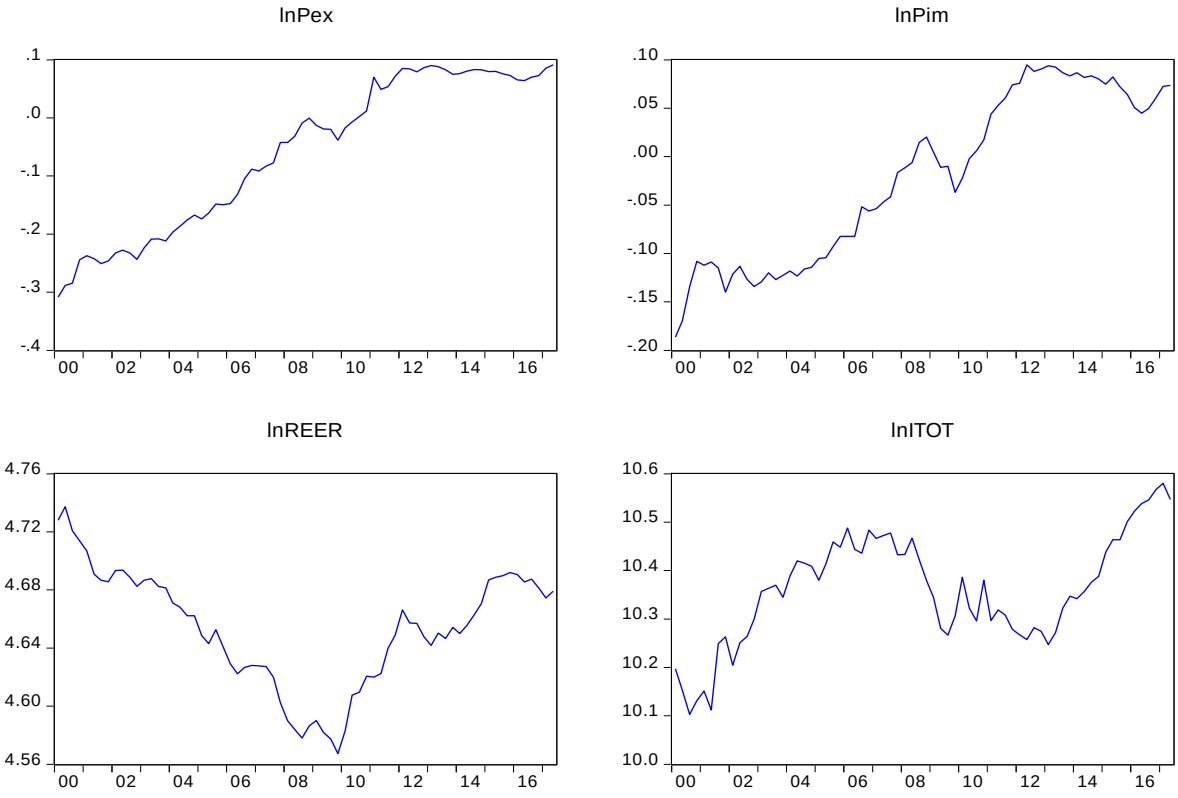
Kako je prethodno definiran vremenski okvir promatranih varijabli, narednim potpoglavljem će varijable modela biti objašnjene i analizirane, odnosno kakve učinke stvaraju na hrvatsko gospodarstvo. Zatim, osim definiranja varijabli biti će prikazan i grafički prikaz varijabli u razinama gdje možemo vidjeti njihov trend kretanja kroz promatrano vremensko razdoblje. Opisom varijabli i teoretskim pretpostavkama koje će biti prikazane moći ćemo donijeti zaključe o tome da li izrada i analiza modela je u skladu sa teorijskom pozadinom promatranih varijabli.

Učinak koji će se promatrati na varijablama upravo su varijable izvozne i uvozne cijene te njihova povezanost sa uvjetima razmjene. S istraženom i proučenom literaturom možemo zaključiti kakva učinak bi varijable imale na gospodarstvo što ćemo i kasnije iz analize modela zaključiti da li je teorijska pozadina sukladna istraživačkom dijelu. Dakle, porast izvoznih cijena, odnosno smanjenje uvoznih cijena rezultirati će poboljšanjem uvjeta razmjene, dok će pad izvoznih cijena, odnosno rast uvoznih cijena rezultirati pogoršanjem uvjeta razmjene. Također, ukoliko izvozne cijene jedne zemlje rastu relativno u odnosu na uvozne cijene kažemo da se uvjeti razmjene za tu zemlju poboljšavaju time da ona ostvaruje više jedinica uvoza po svakoj jedinici izvoza. Zatim, realni efektivni tečaj može utjecati na konkurentnost hrvatskog

gospodarstva, time što određuje cijenu inozemnih dobara u domaćoj valuti i obratno, odvajajući time učinak cijene u varijabli cijena od učinaka promjene deviznog tečaja (Bobić, 2010).

Teoretski devizni tečaj može utjecati na cijene izvoza i uvoza, te se promatranje utjecaja istog na promjenu uvjeta razmjene teoretski gledano možemo zaključiti kako deprecijacija pogoršava uvjete razmjene u dugom roku, odnosno da aprecijacija ima pozitivan efekt na uvjete razmjene. Promatranjem utjecaja koje stvaraju opisane varijable možemo doći do zaključaka kako utječu na hrvatsko gospodarstvo ali i na njezinu konkurentnost. Ujedno sa time da li su značajne za rast i razvoj hrvatskog gospodarstva ili nisu. Promatranjem varijable realnog efektivnog tečaja možemo doći do odgovora kakva je osjetljivost hrvatskog izvoza i uvoza na promjene tečaja, odnosno kako će promjene tečaja utjecati na uvjete razmjene, odnosno na cjelokupno ekonomsko stanje Hrvatske. Važno je navesti kako Bobić (2010) naglašava da je bolje koristiti realni devizni tečaj kao pokazatelj relativnih cijena ako se analiziraju agregatni trgovinski tokovi, iz razloga što se realni tečaj ne razlikuje između sektora. Suprotno navedenome, pretpostavlja se da je bolje koristiti nominalni devizni tečaj.

Grafikon 4. Varijable u razinama



Izvor: Izrada autora (EViews 9.5).

Grafički prikaz prikazuje varijable izvozne cijene (Pex), uvozne cijene (Pim), realni efektivni tečaj (REER) i prihodovne uvjete razmjene (ITOT) u razinama. Iz grafičkog prikaza vidimo da su se varijable promijenile kroz vrijeme. Također, grafički prikaz sugerira da promatrane varijable nisu stacionarne u razinama. Na temelju dobivenih rezultata može se zaključiti da su sve varijable integrirane reda I (1) tj. one su stacionarne u prvim razinama. Također, grafički prikaz sugerira da varijable koje su zastupljene istraživanju pokazuju trendove, odnosno ukoliko promatramo cijelo razdoblje pokazuju trend rasta Navedena pretpostavka omogućila nam je da razmotrimo metodu kointegracije i VEC model. Ukoliko se osvrnemo detaljnije na analizu pojedinih varijabli možemo zaključiti kako izvozne cijene u promatranom razdoblju bilježe povećanje, ali naravno s povremenim oscilacijama. Izvozne cijene su imale trend rasta do financijske krize, a nakon toga zabilježile su smanjenje. Svoje povećanje zabilježile su 2010Q1 i od tada imaju rastući trend. S druge strane ukoliko promatramo uvozne cijene, one su imale također pozitivan trend do financijske krize, no nakon toga zabilježile su smanjenje. Isto kao i izvozne cijene, uvozne cijene svoje povećanje zabilježile su 2010. godine i od tada imaju rastući trend. Analizom sljedeće varijable, odnosno realnog efektivnog tečaja možemo zaključiti kako je do financijske krize tečaj deprecirao, dok s druge strane od 2009. godine tečaj aprecira. Naravno kao i ostale varijable tako je i tečaj tijekom promatranog vremena oscilirao.

Na kraju, posljednji grafikon prikazuje prihodovne uvjete razmjene. Na temelju grafikona možemo zaključiti kako su prihodovni uvjeti razmjene tijekom promatranog razdoblja također oscilirali. Što znači da su do financijske krize prihodovni uvjeti razmjene zabilježili povećanje, dok nakon toga bilježe smanjenje, ali od 2013. godine prihodovni uvjeti bilježe rast. Ukoliko se sagleda cjelokupno razdoblje možemo zaključiti kako su prihodovni uvjeti razmjene zabilježili povećanje isto kao i sve ostale varijable koje su uzete u analizu. Potrebno je istaknuti kako promatrane varijable imaju uzlaznu putanju usprkos krizi koja je bila prisutna u Republici Hrvatskoj. Također kako je vremenska serija podataka široka možemo zaključiti kako je kriza negativno utjecala na promatrane varijable, no ipak vidljiv je trend oporavka. Potrebno je navesti kako takvo stanje u Hrvatskoj prvenstveno bilo uzrokom financijske krize, ali isto tako razlog tome je i što su zemlje EU bile u krizi. Navedeno možemo povezati sa time što zemlje EU predstavljaju najvažnije partnere Republike Hrvatske te se je iz tog razloga kriza također odrazila na njezino gospodarstvo.

5.4. Odabir vremenskih pomaka (lagova) i kointegracijskog ranga

Kako bismo odredili red VAR-a tj. broj vremenskih pomaka učiniti ćemo to pomoću vektorske autoregresije koja se koristi za predviđanje vremenskih serija. Odabir vremenskih pomaka odabrati ćemo putem testova reda VAR-a koji jesu: AIC, HQ, SC, FPE, LogL i LR test. Daljnjim slijedom rada testovi će biti objašnjeni te će biti prikazan odabir lagova za model. Glavna stavka kod odabira reda VAR-a je minimizirati vrijednosti. Tako kada biramo red VAR-a koji minimizira FPE vrijednosti uzimamo ga kao ocjenu za p. Zatim, kod AIC bira se red VAR-a koji minimizira AIC, također isto i kod HQ i SC.

Kod malih uzoraka FPE i AIC kriteriji superiorniji su od HQ i SC kriterija, dok u prisustvu nestacionarnih procesa AIC i FPE kriteriji inferiorniji su od HQ i SC kriterija zadržavaju svoju konzistentnost i u prisustvu nestabilnih procesa. Red VAR-a testirat ćemo pomoću Schwarzovog kriterija (SC kriterij) kod kojeg se odabire broj vremenskih pomaka koji minimiziraju taj kriterij. Razlog zašto ćemo odabrati SC kriterij u odnosu na druge kriterije poput HQ kriterija ili AIC kriterija je u tome što je SC kriterij najrestriktivnijeg pristupa (Belullo, 2008).

Kako ćemo u modelu analizirati veći broj varijabli (u našem slučaju 4 varijable), moguće je ustanoviti veći broj linearnih veza između kointegracije što bi uzrokovalo poteškoće prilikom procjene modela. Uvođenjem restriktivnijeg SC kriterija smanjiti ćemo mogućnost uočavanja većeg broja kointegracijskih veza. Zatim, ako nismo u potpunosti sigurni u red VAR-a možemo koristiti i ostale metode poput Waldovog testa isključivanja vremenskih pomaka koji treba potvrditi broj vremenskih pomaka koje daje SC kriterij.

Tablica 3. Odabir vremenskih pomaka

Lag	LogL	LR	FPE	AIC	SC	HQ
0	438.4361	NA	1.49e-11	-13.57613	-13.44120	-13.52297
1	768.9245	609.3380	8.06e-16	-23.40389	-22.72924*	-23.13811*
2	787.5741	32.05399	7.47e-16	-23.48669	-22.27232	-23.00829
3	799.4886	18.98867	8.62e-16	-23.35902	-21.60493	-22.66799
4	819.8479	29.90270	7.74e-16	-23.49525	-21.20143	-22.59160
5	839.9817	27.05479*	7.14e-16*	-23.62443*	-20.79089	-22.50816
6	855.6006	19.03557	7.79e-16	-23.61252	-20.23926	-22.28362

Izvor: Izračun autora (EViews 9.5).

Broj lagova u VAR modelu određen je standardnim kriterijima (AIC, HQ, SC, FPE, LogL i LR test). Iako su kriteriji pokazali sličan broj odstupanja, konačni model procijenjen je korištenjem jednog laga kako su sugerirali SC i HQ testovi koji su najrestriktivniji. Što se tiče ostalih testova LR i FPE test sugerirali su 5 vremenskih pomaka. Za određivanje broja kointegracijskih vektora uveden je Johansenov postupak reduciranog ranga. S obzirom na pet različitih modela, procjene su napravljene uključivanjem konstante i bez trenda u kointegracijskom prostoru nakon LR testa. Navedeni model pokazao je najbolja svojstva. Procijenili smo VAR (1) koji je pokazao odgovarajuća svojstva.

Tablica 4. Odabir kointegracijskog ranga

Data Trend:	None	None	Linear	Linear	Quadratic
Test Type	No Intercept No Trend	Intercept No Trend	Intercept No Trend	Intercept Trend	Intercept Trend
Trace	2	2	1	1	1
Max-Eig	2	2	1	1	1

Izvor: Izračun autora (EViews 9.5).

Prvi kointegracijski vektor normaliziran je s obzirom na izvozne cijene, dok drugi vektor kointegracije s obzirom na uvozne cijene. Kako je model napravljen uključivanjem konstante i bez trenda rezultati LR testa sugeriraju dvije kointegracijske veze. Ponekad se može otkriti više od jednog kointegracijskog vektora u sustavu s više od dvije varijable koristeći Johansenov postupak. U našoj situaciji, smanjena regresijska procedura zapravo daje informacije o tome koliko jedinstvenih kointegriranih vektora obuhvaća prostor za kointegraciju, dok je svaka linearna kombinacija stacionarnih vektora sam stacionarni vektor, pa stoga procjene proizvedene za bilo koji stupac u β nisu nužno jedinstvene. Ukoliko bi bilo potrebno, nula ograničenja također bi mogla biti postavljena na kratkoročnu dinamiku na α. U skladu s uvjetima određenim u modelima primijenili smo jedinstvenu lnPex homogenost ograničenje na prvi vektor i lnPim homogenost ograničenja na drugi vektor. Time, smo slijedili nula ograničenja na druge β i neke α koeficijente što znači da se nameću ograničenja slabe egzogenosti. U skladu s time, procjena LR testa sugerira de se ograničenja identifikacije u svim modelima ne mogu odbaciti što u konačnici znači da su modeli ispravno određeni. Daljnjim slijedom rada prikazati će se srž ovog rada, odnosno prikazana će biti kratkoročna i dugoročna dinamika modela sa popraćenim rezultatima analize.

5.5. Dugi rok- Johansenova kointegracija

U skladu prethodno definiranim jednadžbama modela možemo procijeniti dugoročnu dinamiku, odnosno Johnasenovu kointegraciju. Daljnjim slijedom rada biti će prikazani rezultati kointegracije modela u dugom roku s dva kointegracijska vektora koja smo ustanovili. Prikazani rezultati će sugerirati do kojih smo zaključaka došli, no potpuni izračun modela može se vidjeti u *Prilogu 1*.

$$\ln Pex_t = 0.78 + 1.24\ \ln Pim_t - 0.22\ \ln REER_t + 0.17\ \ln ITOT_t$$

(0.69)	(0.05)	(0.11)	(0.04)
[1.13]	[-24.73]***	[2.09]**	[-4.50]***

$$\ln Pim_t = 0.05 + 0.65\ \ln Pex_t + 0.18\ \ln REER_t - 0.07\ \ln ITOT_t + \varepsilon_{2,t}$$

(0.52)	(0.03)	(0.08)	(0.03)
[0.12]	[-24.71]***	[-2.22]***	[2.46]***

Rezultati dugog roka pokazuju očekivani teorijski odnos. Nadalje, LR test za restrikciju vezivanja potvrdio je da se sva ograničenja identifikacije u oba modela ne mogu odbaciti, a dijagnostički testovi sugeriraju da su modeli adekvatno procijenjeni, odnosno karakteristike modela su prihvatljive. Procjene modela pokazuju da nema nikakvih problema sa heteroskedastičnosti i normalnosti reziduala što nam je omogućilo donijeti stabilne zaključke. Rezultati testova će biti objašnjeni i prikazani nakon rezultata kointegracije. Rezultati sugeriraju da su cijene izvoza i cijene uvoza objašnjene jedna s drugom i zajedničkim šokovima koji ih vode zajedno. Što se tiče realnog efektivnog tečaja i uvjeta razmjene u Republici Hrvatskoj imaju statistički značajne implikacije u kretanju izvoznih i uvoznih cijena kako u kratkom tako i u dugom roku ali naravno s različitom snagom i smjerom. Ukupni rezultati sugeriraju da su cijene izvoza pozitivno povezane sa cijenama uvoza i sa prihodovnim uvjetima razmjene, dok s druge strane su negativno povezane s realnim efektivnim tečajem. Interpretacija koeficijenata elastičnosti u dugom roku glasi: ako se nezavisna varijabla poveća za 1%, koliko će se promijeniti zavisna varijabla. Porast uvoznih cijena od 1% rezultira povećanjem izvoznih cijena od 1,24% što upućuje na snažan učinak prelijevanja, dok porast prihodovnih uvjeta razmjene od 1% povećava rast cijena izvoza za 0,17% što implicira da povećanje u trgovinskim dobicima nije proizašlo iz izvoznih cijena čime se ugrožava međunarodna konkurentnost. Prilikom interpretacije realnog efektivnog tečaja možemo zaključiti kako 1% deprecijacije domaće valute rezultira smanjenjem izvoznih cijena od 0,22% što znači da hrvatski izvoznici uzimaju

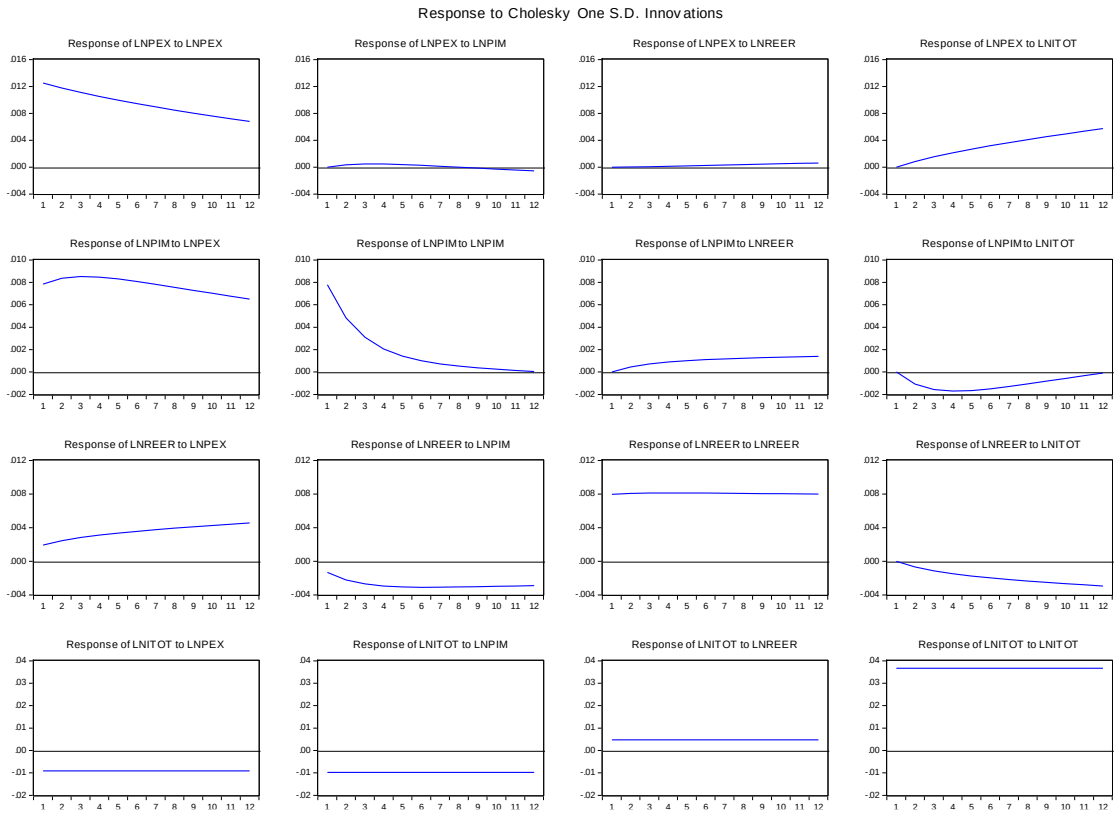
u obzir inozemnu konkurentnu cijenu prilikom određivanja inozemnih cijena. Međutim, navedeni učinak je prilično slab što upućuje na relativno nizak prolazni učinak tečaja na cijene izvoza. S druge strane, kada promatramo uvozne cijene vidimo da su pozitivno povezane sa izvoznim cijenama i realnim efektivnim tečajem, ali negativno s prihodovnim uvjetima razmjene. Dakle, prema objašnjenju porast cijena izvoza od 1% dovodi do porasta uvoznih cijena za 0,65% što je dosljedno s prethodno navedenim pretpostavkama da se trgovinski dobici i nacionalni dohodak prenose na cijene izvoza. Nadalje, možemo zaključiti da 1% deprecijacije domaće valute dovodi do povećanja uvoznih cijena za 0,18% što opet sugerira nizak prolazni učinak ali ovaj put na strani cijena uvoza. Što se tiče prihodovnih uvjeta razmjene možemo zaključiti da povećanje od 1% dovodi do smanjenja uvoznih cijena za 0,07%.

Kako bi donijeli zaključak o ispravnosti modela testirali smo ga na test autokorelacije, zatim heteroskedastičnosti i normalnosti distribucije prema kojem ćemo vidjeti ispravnost modela. U *Prilogu 2.* će biti prikazani testovi i njihovi rezultati što pokazuje da će slijedom rada biti objašnjeno postoji li kakav problem sa kojim od navedena tri testa. Rezultati LM testa pokazuju kako nemamo problema sa autokorelacijom. Možemo zaključiti da model nema problema sa autokorelacijom, odnosno možemo odbaciti hipotezu na 5% značajnosti da imamo problema sa autokorelacijom. Sljedeći test u nizu je test heteroskedastičnosti, gdje možemo zaključiti kako nemamo problema sa heteroskedastičnosti tj. p vrijednost je > od 0,05. Drugim riječima, ne postoji problem sa heteroskedastičnosti, odnosno možemo odbaciti hipotezu na 5% značajnosti da imamo problema sa heteroskedastičnosti. Zadnji test u nizu je test normalnosti distribucije koji nam ukazuje na problem normalnosti distribucije.

5.6. Dekompozicija varijance i impulsne funkcije

Sljedećim potpoglavljem analizirati ćemo dekompoziciju varijance i impulsne funkcije koje smo u mogućnosti analizirati zbog ispravno postavljenog modela. Impulsne funkcije prikazuju za koliko razdoblja se varijable vraćaju u početnu ravnotežu. Možemo zaključiti kako impulsne funkcije nisu značajne za naš model. Tako prema Choleskyjevom redoslijedu stavimo koja varijabla je zavisna i promatramo da li ima utjecaj na ostale varijable.

Grafikon 5. Impulsne funkcije



Izvor: Izrada autora (EViews 9.5).

Tako možemo zaključiti kako jedinično povećanje izvoznih cijena nema određenog utjecaja na uvozne cijene i realni efektivni tečaj, dok s druge strane pozitivno utječe na prihodovne uvjete razmjene. Ukoliko promatramo jedinično povećanje uvoznih cijena možemo zaključiti kako negativno utječu na izvozne cijene i prihodovne uvjete razmjene, dok pozitivno utječu na realni efektivni tečaj. Ukoliko promatramo jedinično povećanje realnog efektivnog tečaja, možemo zaključiti kako pozitivno utječe na izvozne cijene ali negativno na uvozne cijene i na prihodovne uvjete razmjene. Na kraju, kada se sagleda jedinično povećanje prihodovnih uvjeta razmjene na ostale varijable, možemo zaključiti kako nema određenog utjecaja. U slijedu rada biti će grafički prikazane impulsne funkcije svih varijabli modela.

Osim impulsnih funkcija potrebno je sagledati i dekompoziciju varijance. Prikazuje nam razdoblja, te postotke koliko svaka varijabla objašnjava samu sebe ali i druge varijable. Znači za izračun dekompozicije varijance uzeli smo 12 razdoblja, te smo prema Woldovom redoslijedu stavili koja će varijabla biti zavisna. Potpuni prikazi dekompozicije varijance će biti prikazani nakon objašnjenja. Ukoliko kao zavisnu varijablu stavimo izvozne cijene, možemo zaključiti da u prvom razdoblju objašnjava sama sebe sa 100%, dok u posljednjem (12 razdoblju) objašnjava sebe sa 86,95%. Druga u nizu varijabli su izvozne cijene koje se u prvom razdoblju objašnjavaju sa 49,68%, dok u posljednjem sa 11,98%. Zatim ako sagledamo sljedeću varijablu, odnosno realni efektivni tečaj, možemo zaključiti kako u prvom razdoblju objašnjava sebe sa 92,00%, dok u posljednjem razdoblju objašnjava sebe sa 72,01%. Na kraju, posljednja varijabla, prihodovni uvjeti razmjene u prvom razdoblju objašnjavaju sebe sa 87,02%, dok u posljednjem razdoblju objašnjavaju sebe sa isto sa 87,02%. U slijedu rada će biti prikazana tablica dekompozicije varijance.

Tablica 5. Dekompozicija varijance

Variance Decomposition of LNPEX:					
Period	S.E.	LNPEX	LNPIM	LNREER	LNITOT
1	0.012504	100.0000	0.000000	0.000000	0.000000
2	0.017184	99.72744	0.040354	3.34E-05	0.232174
3	0.020517	99.21101	0.079184	0.000595	0.709210
4	0.023151	98.50321	0.100580	0.002471	1.393740
5	0.025344	97.62192	0.105826	0.006340	2.265909
6	0.027231	96.57241	0.100756	0.012697	3.314140
7	0.028895	95.35664	0.091379	0.021859	4.530124
8	0.030392	93.97723	0.082630	0.034003	5.906140
9	0.031761	92.43892	0.078205	0.049195	7.433681
10	0.033032	90.74904	0.080731	0.067413	9.102816
11	0.034228	88.91746	0.091972	0.088566	10.90200
12	0.035367	86.95634	0.113029	0.112505	12.81813
Variance Decomposition of LNPIM:					
Period	S.E.	LNPEX	LNPIM	LNREER	LNITOT
1	0.011057	50.31674	49.68326	0.000000	0.000000
2	0.014732	60.62692	38.73619	0.090966	0.545922
3	0.017384	67.57826	30.97896	0.236305	1.206475
4	0.019542	72.26551	25.61860	0.397177	1.718717
5	0.021369	75.53858	21.86353	0.558551	2.039341
6	0.022943	77.92606	19.15839	0.716413	2.199144
7	0.024314	79.73805	17.14846	0.870834	2.242655
8	0.025518	81.15662	15.61086	1.023083	2.209430

9	0.026584	82.29123	14.40378	1.174567	2.130428
10	0.027534	83.20982	13.43482	1.326486	2.028881
11	0.028387	83.95603	12.64217	1.479767	1.922037
12	0.029157	84.55880	11.98338	1.635077	1.822745

Variance Decomposition of LNREER:

Period	S.E.	LNPEX	LNPIM	LNREER	LNITOT
1	0.008297	5.412453	2.583689	92.00386	0.000000
2	0.012049	6.674930	4.627516	88.37329	0.324262
3	0.015081	7.746347	6.160005	85.30047	0.793178
4	0.017719	8.686606	7.225538	82.79994	1.287913
5	0.020088	9.537535	7.939531	80.75033	1.772603
6	0.022259	10.32604	8.403226	79.03162	2.239112
7	0.024274	11.06916	8.691345	77.55154	2.687961
8	0.026167	11.77769	8.856265	76.24422	3.121825
9	0.027960	12.45856	8.934197	75.06382	3.543415
10	0.029670	13.11626	8.950231	73.97861	3.954898
11	0.031310	13.75371	8.921904	72.96656	4.357831
12	0.032892	14.37285	8.861626	72.01226	4.753256

Variance Decomposition of LNITOT:

Period	S.E.	LNPEX	LNPIM	LNREER	LNITOT
1	0.039325	5.343631	6.161995	1.466607	87.02777
2	0.055614	5.343631	6.161995	1.466607	87.02777
3	0.068113	5.343631	6.161995	1.466607	87.02777
4	0.078650	5.343631	6.161995	1.466607	87.02777
5	0.087934	5.343631	6.161995	1.466607	87.02777
6	0.096327	5.343631	6.161995	1.466607	87.02777
7	0.104045	5.343631	6.161995	1.466607	87.02777
8	0.111228	5.343631	6.161995	1.466607	87.02777
9	0.117975	5.343631	6.161995	1.466607	87.02777
10	0.124357	5.343631	6.161995	1.466607	87.02777
11	0.130427	5.343631	6.161995	1.466607	87.02777
12	0.136226	5.343631	6.161995	1.466607	87.02777

Cholesky Ordering: LNPEX LNPIM LNREER LNITOT

Izvor: Izračun autora (EViews 9.5).

5.7. Kratki rok – uvjetni VEC model

Rezultati modela kratkog roka prikazani su uvjetnim VEC modelom. Općenito, svi rezultati u kratkom roku su u skladu s dugoročnim rezultatima analize i dugoročnom elastičnošću koeficijenata koja je veća u kratkoročnoj dinamici. Navedeno znači kako strani i domaći izvoznici i uvoznici apsorbiraju neposredne promjene u relevantnim međunarodnim varijablama. Rezultati uvjetnog VEC modela biti će prikazani u tablicama koje slijede *(Tablica 4. i Tablica 5.).* Potpuni prikaz modela kao i dijagnostičkih testova dostupni su u *Prilogu 3.*

Tablica 6. Rezultati uvjetnog VEC modela za izvozne cijene

Dependent variable **dlnPex**				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.00*	0.00	1.94	0.06
d(lnPex(-1))	-0.28*	0.16	-1.72	0.09
d(lnPex(-2))	-0.57***	0.18	-3.11	0.00
d(lnPex(-3))	-0.49***	0.16	-3.06	0.00
d(lnPim(-1))	0.36*	0.19	1.93	0.06
d(lnPim(-2))	0.42**	0.21	2.04	0.05
d(lnPim(-3))	0.55***	0.17	3.23	0.00
d(lnREER(-2))	-0.42**	0.16	-2.62	0.01
d(lnITOT(-4))	0.08*	0.04	1.98	0.05
COINTEQ02(-1)	-0.43**	0.15	-2.90	0.01
D2 (2009:Q4)	-0.03**	0.01	-2.34	0.02
R-squared = 0.38, Adjusted R-squared = 0.27, F-statistic (3.32) = 0.00, Durbin-Watson stat = 1.79, Q-statistic probabilities (4) = 0.13, Normality of residuals = 0.00, Breusch-Godfrey Serial Correlation LM Test Prob. F (4,50) = 0.19 and $\chi^2(4) = 0.12$, Heteroskedasticity Test: Breusch-Pagan-Godfrey Prob. F (10,54) = 0.07 and $\chi^2(4) = 0.08$				

Izvor: Izračun autora (EViews 9.5).

Tablica 4. prikazuje rezultate kratkoročne dinamike uvjetnog VEC modela za zavisnu varijablu izvozne cijene (lnPex). Uvozne cijene i prihodovni uvjeti razmjene pokazuju statistički značajan pozitivan utjecaj na zavisnu varijablu na 1%, 5% i 10% razini značajnosti. Nadalje, od ostalih varijabli prisutnih u modelu, možemo zaključiti kako varijabla realni efektivni tečaj i dummy varijabla pokazuju statistički značajan (1%, 5% razina značajnosti), ali negativan utjecaj na zavisnu varijablu. Možemo zaključiti da je dosadašnja analiza sukladna dugoročnoj dinamici. Također u rezultatima prisutnim u tablici nalazi se i procijenjena pogreška odstupanja varijabli (COINTEQ02(-1)) koja je statistički značajna. Možemo zaključiti kako se kratkoročna odstupanja prilagođavaju dugoročno stabilnoj ravnoteži. Razlog tome je što procijenjena pogreška odstupanja koja je statistički značajna i negativnog predznaka osigurava prilagođavanje sustava time da smanjuje neravnotežu kroz vrijeme.

Isto kao i za dugoročnu dinamiku, kako bi se provjerila ispravnost modela provedeni su dijagnostički testovi kvalitete modela. Potpuni prikazi testova dostupni su u *Prilogu 4*. Naime možemo zaključiti kako model prema testu autokorelacije nema problema sa autokorelacijom (p vrijednosti su > od 0,05). Dakle možemo odbaciti hipotezu na razini 5% značajnosti da imamo problema sa autokorelacijom. Nadalje, Breusch-Pagan-Godfrey test za heteroskedastičnost potvrdio je da nemamo problema sa heteroskedastičnosti, odnosno možemo odbaciti hipotezu na 5% značajnosti da imamo problema sa heteroskedastičnosti. I posljednji test je test normalnosti distribucije koji sugerira da imamo problema sa normalnošću distribucije.

Tablica 7. Rezultati uvjetnog VEC modela za uvozne cijene

Dependent variable **dlnPim**				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.00	0.00	-1.05	0.32
d(lnPim(-3))	0.18*	0.10	1.79	0.08
d(lnREER(-1))	0.29**	0.15	1.98	0.05
d(lnITOT(-2))	0.07**	0.03	2.21	0.03
COINTEQ02(-1)	-0.36***	0.12	-3.06	0.00
D1 (2008:Q1-Q4)	0.01**	0.01	2.38	0.02
D2 (2009:Q4)	-0.02**	0.01	-2.32	0.02
R-squared = 0.33, Adjusted R-squared = 0.26, F-statistic (4.82) = 0.00, Durbin-Watson stat = 1.95, Q-statistic probabilities (4) = 0.61, Normality of residuals = 0.01, Breusch-Godfrey Serial Correlation LM Test Prob. F (4,55) = 0.81 and $\chi^2(4) = 0.77$, Heteroskedasticity Test: Breusch-Pagan-Godfrey Prob. F(6,59) = 0.84 and $\chi^2(6) = 0.82$				

Izvor: Izračun autora (EViews 9.5).

Tablica 5. prikazuje analizu uvjetnog VEC modela ali sada za zavisnu varijablu uvozne cijene (lnPim). Za potpuni prikaz modela pogledati *Prilog 5*. Prvo, što možemo zaključiti je da izvozne cijene nemaju nikakav utjecaj na zavisnu varijablu, odnosno na uvozne cijene. Nadalje, realni efektivni tečaj i prihodovni uvjeti razmjene pokazuju statistički značajan pozitivan utjecaj na zavisnu varijablu na 1% i 5% značajnosti. Također što se ostalih varijabli modela tiče možemo zaključiti kako dummy varijabla (D1) ima pozitivan i statistički značajan (1%,5% razina značajnosti) utjecaj na zavisnu varijablu. S druge strane dummy varijabla D2 ima također značajan (1%,5% razina značajnosti) ali negativan utjecaj na zavisnu varijablu. Nadalje u tablici je prisutna i procijenjena pogreška odstupanja varijabli (COINTEQ02(-1)) koja je statistički značajna. Možemo zaključiti kako se kratkoročna odstupanja prilagođavaju dugoročno stabilnoj ravnoteži. Isto ako i za prethodni uvjetni VEC model sa zavisnom varijablom lnPex, i za ovaj model testirani su dijagnostički testovi kvalitete modela. Možemo zaključiti kako model nema problema sa autokorelacijom (p vrijednosti > od 0,05), možemo odbaciti hipotezu na

razini 5% značajnosti da imamo problema sa autokorelacijom modela. Nadalje, test heteroskedastičnosti proveli smo putem Breusch-Pagan-Godfrey testa. Možemo zaključiti kako model nema problema sa heteroskedastičnosti, odnosno možemo odbaciti hipotezu na razini 5% značajnosti da imamo problema sa heteroskedastičnosti. Na kraju, posljednji test u nizu je test normalnosti distribucije prema kojemu imamo problema sa normalnošću distribucije isto kao i u prethodnom modelu. Za potpune izračune testova kvalitete modela pogledati *Prilog 6*.

5.8. Evaluacija rezultata

Opći zaključak analize je da problem hrvatske trgovinske perspektive ne leži u cijenama izvoza, cijenama uvoza, niti u politici tečaja već u strukturi i konkurentnosti hrvatske industrije. Moguće objašnjenje proizlazi iz toga da su cijene izvoza i uvoza egzogene varijable, te da nisu određene na domaćem tržištu, nego su podložne promjenama cijena na svjetskom tržištu. Rezultati sugeriraju kako se prihodovni uvjeti razmjene (prihodovni uvjeti razmjene dobara) u promatranome razdoblju poboljšavaju, odnosno važno za naglasiti je da prihodovni uvjeti za dobra pokazuju snažniju tendenciju rasta. Nadalje, svjetsko tržište diktira cijene dobara, odnosno svjetska ponuda i potražnja su pod utjecajem razvijenih zemalja. Zemlje u razvoju uglavnom su izložene fluktuacijama u uvjetima razmjene, stoga niti ne mogu utjecati na definiranje svojih izvoznih cijena. Osim prihodovnih uvjeta razmjene i izvoznih i uvoznih cijena važan utjecaj ima i realni efektivni tečaj. Možemo zaključiti kako povećanje indeksa realnog deviznog tečaja kune (deprecijacija) vodi poboljšavanju uvjeta razmjene.

Provedena analiza obuhvaćala je kvartalne podatke i to za razdoblje 2000Q1 do 2017Q2, za promatrane varijable. Prilikom izrade modela korištena je Johansenova metodologija kako bi opisali dugoročnu dinamiku i uvjetni VEC model za kratkoročnu dinamiku. Važno je napomenuti kako u otvorenim gospodarstvima tečaj predstavlja jedan od najznačajnijih makroekonomskih pokazatelja. Također, uvjeti razmjene pokazuju da li će zemlja ostvariti neto dobit ili neto gubitak kao posljedica u trgovini i volumenu izvoza što ovisi o elastičnosti potražnje za izvozom.

Sukladno rezultatima u dugom roku, možemo zaključiti kako su cijene izvoza pozitivno povezane s cijenama uvoza ali i sa prihodovnim uvjetima razmjene. Odnosno, analizom realnog efektivnog tečaja možemo zaključiti da 1% deprecijacije domaće valute dovodi do smanjenja izvoznih cijena. S druge strane, kada za zavisnu varijablu imamo uvozne cijene, možemo

zaključiti kako su pozitivno povezane sa izvoznim cijenama i realnim efektivnim tečajem, no negativno povezane sa prihodovnim uvjetima razmjene. Zatim u ovom slučaju deprecijacija od 1% dovodi do povećanja uvoznih cijena. Što se tiče analize u kratkom roku, možemo zaključiti da su rezultati konzistentni sa dugoročnom dinamikom kako je prethodno objašnjeno. Rezultati pokazuju veću osjetljivost izvoznih i uvoznih cijena na njihov međusobni odnos i nižu osjetljivost na kretanje uvoznih cijena i realnog efektivnog tečaja.

Navedene zaključke možemo potkrijepiti i sa istraženom literaturom, odnosno rezultati modela pokazuju da su u skladu s postojećom empirijskom bazom. Tako, Tomić (2012) zaključuje kako su uvjeti razmjene bitan faktor napretka hrvatskog gospodarstva, te da međunarodna razmjena ima značajnu ulogu u njezinom napretku. Također, Tomić (2014) zaključuje kako je izvozna perspektiva značajna za mala otvorena gospodarstva upravo kao što je Hrvatska. Cilj ovog rada je bio analizirati kako promjene u uvjetima razmjene i tečaj utječu na cijene izvoza i cijene uvoza. Jedna važna značajka ovog istraživanja upravo su kvartalni podaci koji su korišteni za analizu i interpretaciju modela. Razlog korištenja kvartalnih podataka je u otkrivanju kratkoročne dinamike koja ostaje sakrivena u godišnjim podacima. Na kraju, analize rezultata možemo zaključiti da iako je Hrvatska mala zemlja ona može pomoću izvozne strategije pospješiti svoj nastup na međunarodnom tržištu. Uz sve navedeno možemo zaključiti kako su upravo uvjeti razmjene ključna stvar njezina napretka.

6. ZAKLJUČAK

Hrvatska kao malo, otvoreno gospodarstvo ima široki spektar mogućnosti razvoja svog gospodarstva. Iako je mala zemlja, možemo reći da ima potencijala za napredak i bolji nastup na međunarodnom tržištu. Kako temelj ovog rada predstavljaju uvjeti razmjene, odnosno izvozne i uvozne cijene te realni efektivni tečaj, možemo zaključiti kako značaj i uloga promatranih varijabli u Hrvatskoj još uvijek nije na dostatnoj razini. Kako uvjeti razmjene imaju jednu od ključnih uloga u gospodarskom rastu, smatramo da bi se trebao pridavati sve veći značaj uvjetima razmjene jer upravo oni predstavljaju pokretač gospodarskog sustava. Nadalje, potrebo je istaknuti kako je Hrvatska uvidjela kako izvozom može pospješiti svoj napredak, no s druge strane javljaju se poteškoće u ostvarenju istog. Uzrok tome upravo je već navedeno kako je Hrvatska mala zemlja koju karakterizira usitnjenost proizvodnje ali, i nedostatnost proizvodnih kapaciteta za nastup na međunarodnom tržištu. Sa svime navedenim, možemo zaključiti i napomenuti kako ono najvažnije za Hrvatsku je upravo izvozna strategija. Također, sa kvalitetno postavljenim ciljevima može se postići željeni pozitivan učinak na gospodarstvo. Nadalje, od navedenih problema smatramo da se ne bi trebao shvaćati olako, no ipak ključni problem predstavlja izvozna strategija. Vidljivo je kako Hrvatska stavlja sve veću pozornost na izvoznu strategiju, te će samim time poboljšati svoje uvjete razmjene kao ključ napretka pojedine zemlje.

Kako je primarni cilj ovog rada bio utvrditi utjecaj promjena uvjeta razmjena i realnog efektivnog tečaja na izvozne i uvozne cijene Republike Hrvatske za razdoblje od 2000. do 2017. godine, možemo donijeti određene zaključe na temelju provedene ekonometrijske analize. Analiza ekonometrijskog modela predstavlja nam rezultate koji su u skladu sa empirijskom pozadinom ovog rada. Što se tiče znanstvene literature koja je istražena za tematiku ovoga rada možemo zaključiti kako u Hrvatskoj broj znanstvenih radova nije na zavidnoj razini kako je u ostalim zemljama. Potrebno je navesti kako trenutna literatura sugerira prvenstveno značaj uvjeta razmjene za gospodarski napredak, ali i sa time utjecaje ostalih indikatora koji su važni poput izvoznih i uvoznih cijena i tečaja. Analiza ekonometrijskog modela rađena je prema Johansenovoj metodologiji kojom je prikazana dugoročna analiza, dok analiza kratkoročne dinamike prikazana je uvjetnim VEC modelom. Jedan od važnijih elemenata ovog rada upravo su kvartalni podaci kako je prethodno već napomenuto, odnosno koji nam omogućuju detaljnu analizu i zbog kojih smo u mogućnosti prikazati rezultate kratkog roka.

Analiza modela sugerira sljedeće rezultate. Tako, u dugom roku možemo zaključiti kako uvozne cijene dobara su pozitivno korelirane sa zavisnom varijablom, odnosno sa izvoznim cijenama. Nadalje, što se tiče rezultata ostalih varijabli možemo zaključiti kako prihodovni uvjeti razmjene za dobra također pozitivno utječu na izvozne cijene dobara. Time možemo zaključiti kako koncept uvjeta razmjene za Hrvatsku je jedan od faktora za koji se je pokazao kao pozitivan učinak na cijelo gospodarstvo. S druge strane, analiza modela u dugom roku uključuje i analizu realnog efektivnog tečaja koji je prema modelu u ovom radu negativno povezan sa izvoznim cijenama dobara Hrvatske. Naime, interpretacijom koeficijenata možemo zaključiti kako deprecijacija domaće valute sugerira smanjenje izvoznih cijena dobara.

Kako smo modelom procijenili dva kointegracijska ranga drugi dio jednadžbe u dugom roku odnosi se na zavisnu varijablu uvozne cijene dobara. Možemo zaključiti kako su uvozne cijene dobara Hrvatske pozitivno korelirane sa izvoznim cijenama dobara i sa realnim efektivnim tečajem, no negativno su korelirane sa prihodovnim uvjetima razmjene za dobra. Također, važno je napomenuti kako kod izvoznih cijena kao zavisne varijable tečaj je pozitivno utjecao na zavisnu varijablu, odnosno uzrokovao deprecijaciju domaće valute, dok je kod uvoznih cijena dobara kao zavisne varijable deprecijacija tečaja je negativno povezana sa zavisnom varijablom. Analiza modela dugog roka sugerira nam probleme s kojima se susreće Hrvatska ali prikazuje i moguća rješenja kojima bi trebalo pridavati veću i značajnu važnost kao što su uvjeti razmjene.

Sukladno analizi dugog roka, rezultati analize kratkoročne dinamike su u skladu sa dugoročnom dinamikom. Kako je kratki rok generiran korištenjem uvjetnog VEC model došlo se je do određenih rezultata. Naime, prvi model sa zavisnom varijablom izvozne cijene dobara pokazao je pozitivan i statistički značajan utjecaj uvoznih cijena i prihodovnih uvjeta razmjene na zavisnu varijablu, dok je utjecaj realnog efektivnog tečaja također značajan ali negativnog utjecaja. S druge strane, analiza uvjetnog VEC modela ali sada sa zavisnom varijablom uvozne cijene dobara pokazala je da su prihodovni uvjeti razmjene i realni efektivni tečaj značajni i pozitivnog utjecaja na zavisnu varijablu. Možemo zaključiti, kako su modeli dugog i kratkog roka potkrijepljeni sa teorijskom pozadinom, odnosno dokazana je poveznica između njih. Što se kvalitete modela tiče, provedeni su dijagnostički testovi te je dokazano kako su modeli ispravno postavljeni i sa time nam je omogućena kvalitetna interpretacija istih. Osim testova kvalitete modela prikazane su i impulsne funkcije koje ne pokazuju određene značajne efekte, te isto tako prikazana je dekompozicija varijance modela.

Na kraju, možemo zaključiti kako istraživačka struktura rada ukazuje na pozitivan učinak uvjeta razmjene u Hrvatskoj ali također i njezina veza sa tečajem kao instrumentom smatra se ključnim za poticanje izvoza i predstavlja značajan efekt za makroekonomsku politiku Hrvatske. Osim vidljivih utjecaja nastalih promjenom tečaja i uvjeta razmjene, promjene cijena uvoza i izvoza dobara podložne su promjenama koje ovise o relativnim cijenama na svjetskom tržištu. Osobito valja istaknuti kako trend uvjeta razmjene u Hrvatskoj ima uzlazni trend proteklih godina, te sam problem hrvatske izvozne perspektive nije u samim uvjetima razmjene niti u politici tečaja već u samoj strukturi izvoza ali i u konkurentnosti gospodarskih grana Hrvatske.

POPIS LITERATURE

A) KNJIGE

1. **BABIĆ, A. i BABIĆ, M. (2008.)** *Međunarodna ekonomija.* Zagreb: Sigma savjetovanja d.o.o.

2**. BABIĆ, M. (1995.)** *Makroekonomija*. Zagreb: Mate d.o.o.

3. **GRGIĆ, M. i BILAS, V. (2008.)** *Međunarodna ekonomija.* Zagreb: Lares plus d.o.o.

4. **KORDIĆ, G. (2016.)** *Politike i režimi deviznih tečajeva.* Zagreb: Ekonomski fakultet Sveučilišta u Zagrebu .

5. **KRTALIĆ, S. i BENAZIĆ, M. (2010.)** *Financije u vrtlogu globalizacije.* Pula: Sveučilište Jurja Dobrile u Puli.

6. **KRUGMAN, P. R. i OBSTFELD, M. (2009.)** *Međunarodna ekonomija:* Teorija i ekonomska politika. Zagreb: Mate d.o.o.

7. **OBADIĆ, A. i TICA, J. (2016.)** *Gospodarstvo Hrvatske.* Zagreb: Ekonomski fakultet Sveučilišta u Zagrebu.

8. **PERIŠIN, I., ŠOKMAN, A. i LOVRINOVIĆ, I. (2001.)** *Monetarna politika.* Pula: Sveučilište Jurja Dobrile u Puli.

9. **SHARMA, S. i TOMIĆ, D. (2012.)** *Ekonomska politika i makroekonomski management.* Zagreb: Mikrorad.

B) ČLANCI

1. **BALASSA, B (1985.)** *Export, policy choices, and economic growth in developing countries after the 1973. oil shock.* Journal of Development Economics.
2. **BEGOVIĆ, S. i KRESO, S. (2017.)** *The adverse effect of real effective exchange rate on trade balance in European transitions countries.* Rijeka: Ekonomski fakultet u Rijeci. Zbornik radova.
3. **BELULLO, A. (2008.)** *Ekonometrija. Skripta.* Pula: Sveučilište Jurja Dobrile, Odjel za ekonomiju i turizam „Dr. Mijo Mirković".
4. **BERDEN, K. G. (2006.)** *On Technology, Uncertainty and Economic Growth. Tinbergen Institute Research Series.*
5. **BILLMEIER, A. i BONATO, L. (2004.)** *Exchange rate pass through and monetary policy in Croatia.* Journal of Comparative Economics.

6. **BIRDSALL, N. i HAMOUDI, A. (2002.)** *Commodity Dependence, Trade, and Growth: When openness is Not Enough.* Centre for Global Development WorkoPaper.
7. **BOTRIĆ, V. i COTA, B. (2006.)** *Sources of Inflation in Transition Economy: The Case of Croatia.* Zagreb: Ekonomski pregled.
8. **BUTURAC, G.** (2009.) *Structural characteristics of Export and Imports of Croatian Manufacturing.* Zagreb: Ekonomski pregled.
9. **CORRIGAN, T. D. (2005.)** *The Relationship Between Import Prices and Inflation in the United States.* SAD: Journal of Applied Business and Economics.
10. **COUDRHRI, E. U. i HAKURA, D. S. (2012.)** *The Exchange Rate Pass – Through to Import and Export Prices: The Role of Nominal Rigidities and Currency Choice.* IMF Working Paper. International Monetary Fund.
11. **DASH, A. K. i NARASIMHAN, V. (2011.)** *Exchange Rate Pass – through: How much do Exchange Rate Changes Affect the Prices of Indian Exports and Imports.* South Asia Economic Journal.
12. **DICKEY, D. A. i FULLER, W. A. (1981.)** *Likelihood ratio statistic for autoregressive time series with a unit root.* Econometrica.
13. **DIEWERT, W. E. i MORRISON, C. (1986.)** *Productivity and changes in the Terms of Trade in Japan and the U.S.* Massachusetts. National Bureau of Economic Research.
14. **ENGLE, R. F. i GRANGER, C. W. J. (1987.)** *Co- Integration and Error Correction: Representation, Estimation and Testing.* Econometrica.
15. **FATIMA, N. (2010.)** *Analysing the Terms of Trade Effect for Pakistan.* Islamabad: Working Papers. Pakistan Institute for Development Economics
16. **GUTMANN, P. (1981.)** *The measurment of Terms of Trade effect.* Pariz: OECD.
17. **GOLDSTEIN, M. i KHAN, M. (1985.)** *Income and price effects in foreign trade.* Chapter 20 in Handbook of International Economics.
18. **HENRY, K. (2006.)** *Fiscal and Economic Outlook.* Address to the Australian Business Economists. Terasu of Australia.
19. **HERNANDEZ, G. (2011.)** *Terms of Trade and Output Fluctuations in Columbia.* Universtity of Massachusetts.
20. **JABARA, C. (2009.)** *How Do Exchange Rates Affect Import Prices?* Recent Economic Literature and Data Analysis. U.S. International Trade Comission
21. **JOHANSEN, S. (2002.)** *The interpretation of cointegration coefficients in the cointegrated vector autoregressive model.* Reprints of Department of Theoretical Statistic. Universtity of Copenhagen.

22. **KOŠKI, D. (2008.)** *Izbor optimalnog sustava deviznog tečaja za Republiku Hrvatsku.* Zagreb: Izvorni znanstveni rad.
23. **KOVAĆ, I. (2012.)** *Trendovi i karakteristike međunarodne robne razmjene Republike Hrvatske.* Zagreb: Državni zavod za statistiku.
24. **KOVAČEVIĆ, Z. i TOMIĆ, D. (2012.)** *Povezanost uvjeta razmjene, otvorenosti i gospodarskog rasta u Republici Hrvatskoj.* Zagreb: Poslovna izvrsnost. Znanstveni časopis za promicanje kulture, kvalitete i poslovna izvrsnost.
25. **LEE, Y. i KENNEDY, P.L. (2009.)** *Impacts of Exhchange Rate on Terms of Trade and Volume of Trade.* Louisiana State University AgCenter
26. **LI, Y., CHEN, Z. i SAN, C. (2010.)** *Research on the Relationship between Foreign Trade and the GDP Growth of East China—Empirical Analysis Based on Causality.* Modern Economy.
27. **LIU, H. Y. i CHEN, X. L. (2017.)** *The imported price, inflation and exchange rate pass – through in China.* Cogent Economics and Finance.
28. **MAJEED, H. i AFFAT, S. (2014.)** *Relationship between Exports, Imports and Economic Growth ; Saudi Arabia: 1990. – 2011.* Evidence for Co- Integration and Granger Causality Analysis.
29. **MARIĆ, Ž. (2012.)** *Realni devizni tečaj i interno prilagođavanje. Primjer Bosne i Hercegovine.* Prethodno priopćenje.
30. **MENDOZA, E. G. (1997.)** *Terms of trade uncertainty and economic growth.* Journal of Development Economics.
31. **STUČKA, T. (2004.)** *The Effect of Exchange Rate Change on Trade Balance in Croatia*. IMF Working Paper. International Monetary Fund.
32. **ŠIMURINA, J. i TOMIĆ, D.** (2012.) *Analiza efekta uvjeta razmjene u Republici Hrvatskoj.* Zagreb. Zbornik ekonomskog fakulteta u Zagrebu. Stručni rad.
33. **ŠKARE, M et. al. (2012.)** *Income terms of trade trend and volatility in Croatia; A growth perspective.* Zagreb: Economic Research.
34. **ŠOKČEVIĆ, S. (2008.)** *Analiza izvozne sposobnosti hrvatskog gospodarstva primjenom strategije izvozne ekspanzije.* Ekonomski pregled.
35. **TICA, J. (2012.)** *Kvaliteta proizvoda, produktivnosti zemlje i ravnotežni tečaj.* Zagreb: Ekonomski fakultet Zagreb.
36. **TICA, J. i POSEDEL, P. (2009.)** *Threshold Model of the Exchange Rate Pass – Through Effect.* Eastern European Economics.

37. **TOMIĆ, D. (2012.)** *Zašto je važno promatrati kretanje uvjeta razmjene u Republici Hrvatskoj*. Zadar: Oeconomica Jadertina.
38. **TOMIĆ, D. (2014.)** *Može li Hrvatska tražiti izlaz iz gospodarske agonije kroz izvoz.* Osijek: Peta Inter fakultetska znanstvena konferencija. Sveučilište J. J. Strossmayera u Osijeku. Ekonomski fakultet u Osijeku.
39. **TOMIĆ, D. i BUKOVAC, D (2018.)** *What does affect the prices of Croatian exports and imports?* 37th International Conference on Organizational Science Development: Organization and uncertainty in the digital age. Portorož, Slovenija, Ožujak 21-23.
40. **TURČIĆ, Z. (2014.)** *Hrvatsko gospodarstvo u vanjskotrgovinskoj razmjeni.* Zagreb: Poslovna izvrsnost.

C) ELEKTRONIČKI IZVORI INFORMACIJA

1. **BOBIĆ, V. (2010.)** *Dohodovna i cjenovna elastičnost Hrvatske robne razmjene* - analiza panel podataka. [online], Zagreb: HNB. Dostupno na: https://www.hnb.hr/documents/20182/121351/i-029.pdf/fac87b9a-a3cd-47cd-abde-b56a3c528778, pristupljeno 12.3.2018.

2. **DIEWERT, W.E. i LAWRENCE, D. (2006.)** *Measurment the Contributions of Productivity and Terms of Trade to Australia Economic Welfare.* [online] Commonwealth of Australia. Consultancy Report. Dostupno na: https://economics.ubc.ca/files/2013/06/pdf_paper_erwin-diewert-measuring-contribution-australia.pdf, pristupljeno 15.3.2018 .

3. Hrčak; Portal znanstvenih časopisa Republike Hrvatske. Dostupno na: http://hrcak.srce.hr, pristupljeno 2.3.2018.

4. Hrvatska narodna banka (HNB). Dostupno na: http://www.hnb.hr, 6.4.2018.

5. Macroeconomic Analysis. Dostupno na: http://macroeconomicanalysis.com, pristupljeno 2.3.2018.

6. Službena stranica Državnog zavoda za statistiku Republike Hrvatske. Dostupno na: http://www.dzs.hr, pristupljeno 5.4.2018.

D) DISERTACIJE

1. **TOMIĆ, D. (2012.)** *Utjecaj prihodovnih uvjeta razmjene na gospodarsku aktivnost Republike Hrvatske.* Sveučilište u Zagrebu, Ekonomski fakultet, Zagreb.

POPIS TABLICA

Tablica 1. Testiranje jediničnih korijena 29
Tablica 2. Popis varijabli 34
Tablica 3. Odabir vremenskih pomaka 37
Tablica 4. Odabir kointegracijskog ranga 38
Tablica 5. Dekompozicija varijance 42
Tablica 6. Rezultati uvjetnog VEC modela za izvozne cijene 44
Tablica 7. Rezultati uvjetnog VEC modela za uvozne cijene 45

POPIS GRAFIKONA

Grafikon 1. Platna bilanca Republike Hrvatske 12
Grafikon 2. Prikaz indeksa efektivnih tečajeva kune 19
Grafikon 3. Varijable u prvoj diferenciji 31
Grafikon 4. Varijable u razinama 35
Grafikon 5. Impulsne funkcije 41

PRILOZI

Prilog 1

Vector Error Correction Estimates
Sample (adjusted): 2000Q2 2017Q2
Included observations: 69 after adjustments
Standard errors in ( ) & t-statistics in [ ]
Cointegration Restrictions:
B(1,1)=1, B(2,2)=1, A(4,2)=0, A(4,1)=0, A(3,2)=0, A(2,1)=0
Convergence achieved after 103 iterations.
Restrictions identify all cointegrating vectors
LR test for binding restrictions (rank = 2):
Chi-square(2) 0.566835
Probability 0.753205

Cointegrating Eq:	CointEq1	CointEq2
LNPEX(-1)	1.000000	-0.650043
		(0.02631)
		[-24.7062]
LNPIM(-1)	-1.242955	1.000000
	(0.05025)	
	[-24.7349]	
LNREER(-1)	0.223294	-0.181760
	(0.10693)	(0.08183)
	[2.08815]	[-2.22130]
LNITOT(-1)	-0.174289	0.073289
	(0.03874)	(0.02980)
	[-4.49943]	[2.45922]
C	0.784438	0.058845
	(0.69479)	(0.51989)
	[1.12903]	[0.11319]

Error Correction:	D(LNPEX)	D(LNPIM)	D(LNREER)	D(LNITOT)
CointEq1	-0.209220	0.000000	0.107311	0.000000
	(0.04206)	(0.00000)	(0.03767)	(0.00000)
	[-4.97404]	[NA]	[2.84890]	[NA]
CointEq2	-0.189584	-0.404833	0.000000	0.000000
	(0.09538)	(0.08228)	(0.00000)	(0.00000)
	[-1.98757]	[-4.92019]	[NA]	[NA]
R-squared	0.066186	0.153745	0.095504	-0.009789
Adj. R-squared	0.052248	0.141114	0.082004	-0.024861
Sum sq. resids	0.010476	0.008191	0.004613	0.103613
S.E. equation	0.012504	0.011057	0.008297	0.039325
F-statistic	4.748749	12.17232	7.074410	-0.649520
Log likelihood	205.4443	213.9339	233.7444	126.3845
Akaike AIC	-5.896937	-6.143012	-6.717230	-3.605347
Schwarz SC	-5.832180	-6.078255	-6.652473	-3.540590
Mean dependent	0.005799	0.003772	-0.000709	0.005065
S.D. dependent	0.012844	0.011930	0.008660	0.038845

Determinant resid covariance (dof adj.)	8.10E-16
Determinant resid covariance	7.20E-16
Log likelihood	811.0547
Akaike information criterion	-22.98709
Schwarz criterion	-22.40428

ECM model 1

Dependent variable **dlnPex**				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.00*	0.00	1.94	0.06
d(lnPex(-1))	-0.28*	0.16	-1.72	0.09
d(lnPex(-2))	-0.57***	0.18	-3.11	0.00
d(lnPex(-3))	-0.49***	0.16	-3.06	0.00
d(lnPim(-1))	0.36*	0.19	1.93	0.06
d(lnPim(-2))	0.42**	0.21	2.04	0.05
d(lnPim(-3))	0.55***	0.17	3.23	0.00
d(lnREER(-2))	-0.42**	0.16	-2.62	0.01
d(lnITOT(-4))	0.08*	0.04	1.98	0.05
COINTEQ02(-1)	-0.43**	0.15	-2.90	0.01
D2 (2009:Q4)	-0.03**	0.01	-2.34	0.02
R-squared = 0.38, Adjusted R-squared = 0.27, F-statistic (3.32) = 0.00, Durbin-Watson stat = 1.79, Q-statistic probabilities (4) = 0.13, Normality of residuals = 0.00, Breusch-Godfrey Serial Correlation LM Test Prob. F (4,50) = 0.19 and $\chi^2(4) = 0.12$, Heteroskedasticity Test: Breusch-Pagan-Godfrey Prob. F (10,54) = 0.07 and $\chi^2(4) = 0.08$				

ECM model2

Dependent variable **dlnPim**				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.00	0.00	-1.05	0.32
d(lnPim(-3))	0.18*	0.10	1.79	0.08
d(lnREER(-1))	0.29**	0.15	1.98	0.05
d(lnITOT(-2))	0.07**	0.03	2.21	0.03
COINTEQ02(-1)	-0.36***	0.12	-3.06	0.00
D1 (2008:Q1-Q4)	0.01**	0.01	2.38	0.02
D2 (2009:Q4)	-0.02**	0.01	-2.32	0.02
R-squared = 0.33, Adjusted R-squared = 0.26, F-statistic (4.82) = 0.00, Durbin-Watson stat = 1.95, Q-statistic probabilities (4) = 0.61, Normality of residuals = 0.01, Breusch-Godfrey Serial Correlation LM Test Prob. F (4,55) = 0.81 and $\chi^2(4) = 0.77$, Heteroskedasticity Test: Breusch-Pagan-Godfrey Prob. F(6,59) = 0.84 and $\chi^2(6) = 0.82$				

Prilog 2

VEC Residual Normality Tests
Orthogonalization: Cholesky (Lutkepohl)
Null Hypothesis: residuals are multivariate normal
Date: 11/18/17 Time: 08:49
Sample: 2000Q1 2017Q2
Included observations: 69

Component	Skewness	Chi-sq	df	Prob.
1	1.373305	21.68860	1	0.0000
2	0.033174	0.012656	1	0.9104
3	0.274883	0.868948	1	0.3512
4	0.412030	1.952339	1	0.1623
Joint		24.52254	4	0.0001

Component	Kurtosis	Chi-sq	df	Prob.
1	7.359866	54.64925	1	0.0000
2	3.408684	0.480191	1	0.4883
3	2.908284	0.024184	1	0.8764
4	3.963902	2.671181	1	0.1022
Joint		57.82481	4	0.0000

Component	Jarque-Bera	df	Prob.
1	76.33785	2	0.0000
2	0.492847	2	0.7816
3	0.893132	2	0.6398
4	4.623520	2	0.0991
Joint	82.34735	8	0.0000

VEC Residual Heteroskedasticity Tests: No Cross Terms (only levels and squares)
Date: 11/18/17 Time: 08:50
Sample: 2000Q1 2017Q2
Included observations: 69

Joint test:

Chi-sq	df	Prob.
54.20257	40	0.0663

Individual components:

Dependent	R-squared	F(4,64)	Prob.	Chi-sq(4)	Prob.
res1*res1	0.023205	0.380099	0.8220	1.601141	0.8086
res2*res2	0.028438	0.468333	0.7587	1.962248	0.7427
res3*res3	0.141326	2.633379	0.0421	9.751487	0.0448
res4*res4	0.010827	0.175129	0.9504	0.747068	0.9454
res2*res1	0.044767	0.749849	0.5618	3.088957	0.5431
res3*res1	0.161813	3.088815	0.0218	11.16509	0.0248
res3*res2	0.095184	1.683148	0.1648	6.567679	0.1606
res4*res1	0.022964	0.376055	0.8249	1.584496	0.8116
res4*res2	0.008632	0.139309	0.9670	0.595584	0.9636
res4*res3	0.007179	0.115700	0.9765	0.495374	0.9739

VEC Residual Heteroskedasticity Tests: Includes Cross Terms
Date: 11/18/17 Time: 08:50
Sample: 2000Q1 2017Q2
Included observations: 69

Joint test:

Chi-sq	df	Prob.
65.02285	50	0.0751

Individual components:

Dependent	R-squared	F(5,63)	Prob.	Chi-sq(5)	Prob.
res1*res1	0.049962	0.662632	0.6531	3.447402	0.6314
res2*res2	0.083059	1.141345	0.3481	5.731083	0.3333
res3*res3	0.156993	2.346497	0.0512	10.83252	0.0548
res4*res4	0.071012	0.963150	0.4472	4.899845	0.4282
res2*res1	0.087320	1.205488	0.3170	6.025046	0.3038
res3*res1	0.165892	2.505953	0.0392	11.44653	0.0432
res3*res2	0.103332	1.452024	0.2183	7.129911	0.2112
res4*res1	0.026117	0.337899	0.8881	1.802074	0.8758
res4*res2	0.022056	0.284178	0.9201	1.521888	0.9105
res4*res3	0.007186	0.091205	0.9933	0.495865	0.9923

Prilog 3

Parsimonious VEC-m1

d(lnpex) c d(lnpex(-1)) d(lnpex(-2)) d(lnpex(-3)) d(lnpex(-4)) d(lnpim(-1)) d(lnpim(-2)) d(lnpim(-3)) d(lnpim(-4)) d(lnreer(-1)) d(lnreer(-2)) d(lnreer(-3)) d(lnreer(-4)) d(lnitot(-1)) d(lnitot(-2)) d(lnitot(-3)) d(lnitot(-4)) cointeq01(-1) cointeq02(-1)

Dependent Variable: D(LNPEX)
Method: Least Squares
Date: 11/18/17 Time: 13:50
Sample (adjusted): 2001Q2 2017Q2
Included observations: 65 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.004065	0.002094	1.941038	0.0575
D(LNPEX(-1))	-0.276476	0.160373	-1.723961	0.0904
D(LNPEX(-2))	-0.568116	0.182788	-3.108065	0.0030
D(LNPEX(-3))	-0.493682	0.161383	-3.059065	0.0035
D(LNPIM(-1))	0.358401	0.185762	1.929356	0.0589
D(LNPIM(-2))	0.418434	0.205588	2.035304	0.0467
D(LNPIM(-3))	0.545145	0.168859	3.228411	0.0021
D(LNREER(-2))	-0.418529	0.159945	-2.616710	0.0115
D(LNITOT(-4))	0.076311	0.038527	1.980718	0.0527
COINTEQ02(-1)	-0.431988	0.148916	-2.900875	0.0054
D2	-0.026460	0.011310	-2.339537	0.0230

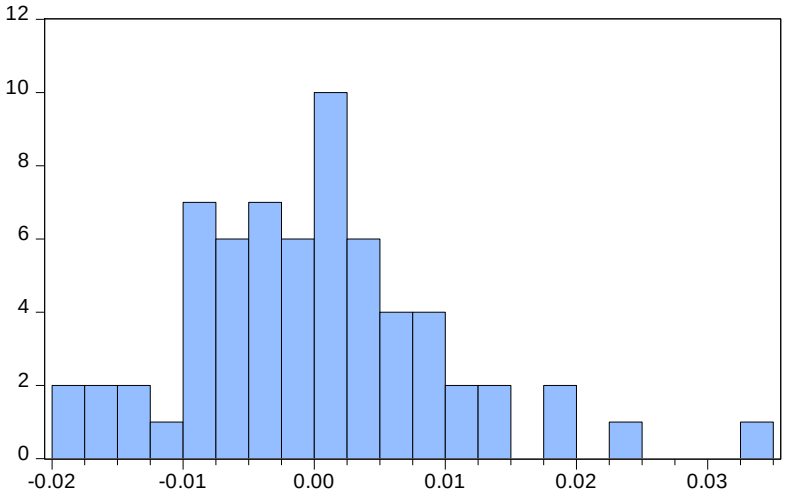
R-squared	0.381066	Mean dependent var	0.005057
Adjusted R-squared	0.266448	S.D. dependent var	0.012354
S.E. of regression	0.010581	Akaike info criterion	-6.106481
Sum squared resid	0.006046	Schwarz criterion	-5.738508
Log likelihood	209.4606	Hannan-Quinn criter.	-5.961292
F-statistic	3.324672	Durbin-Watson stat	1.790747
Prob(F-statistic)	0.002004		

Prilog 4

Date: 11/18/17 Time: 13:53
Sample: 2000Q1 2017Q2
Included observations: 65
Q-statistic probabilities adjusted for 10 dynamic regressors

Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob*
. |*. |	. |*. |	1	0.087	0.087	0.5154	0.473
. |*. |	. |*. |	2	0.139	0.133	1.8595	0.395
. | . |	. | . |	3	0.041	0.020	1.9796	0.577
. |** |	. |** |	4	0.267	0.251	7.0777	0.132

*Probabilities may not be valid for this equation specification.



Series: Residuals
Sample 2001Q2 2017Q2
Observations 65

Mean	-1.33e-18
Median	-5.12e-05
Maximum	0.034370
Minimum	-0.019811
Std. Dev.	0.009719
Skewness	0.746087
Kurtosis	4.548045
Jarque-Bera	12.52070
Probability	0.001911

Breusch-Godfrey Serial Correlation LM Test:

F-statistic	1.604544	Prob. F(4,50)	0.1877
Obs*R-squared	7.394450	Prob. Chi-Square(4)	0.1165

Test Equation:
Dependent Variable: RESID
Method: Least Squares
Date: 11/18/17 Time: 13:55
Sample: 2001Q2 2017Q2
Included observations: 65
Presample missing value lagged residuals set to zero.

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.000491	0.002271	0.216071	0.8298
D(LNPEX(-1))	-0.063676	0.243600	-0.261394	0.7949
D(LNPEX(-2))	-0.036224	0.265388	-0.136495	0.8920
D(LNPEX(-3))	0.041086	0.203802	0.201597	0.8410
D(LNPIM(-1))	-0.064670	0.185637	-0.348367	0.7290

D(LNPIM(-2))	-0.041471	0.230023	-0.180290	0.8577
D(LNPIM(-3))	-0.059350	0.193932	-0.306034	0.7608
D(LNREER(-2))	-0.045622	0.161815	-0.281938	0.7792
D(LNITOT(-4))	0.010169	0.039426	0.257932	0.7975
COINTEQ02(-1)	-0.024013	0.151451	-0.158550	0.8747
D2	-0.004844	0.011295	-0.428890	0.6698
RESID(-1)	0.177071	0.256539	0.690228	0.4932
RESID(-2)	0.171389	0.244398	0.701272	0.4864
RESID(-3)	-0.026927	0.231696	-0.116216	0.9079
RESID(-4)	0.282779	0.165560	1.708020	0.0938

R-squared	0.113761	Mean dependent var	-1.33E-18
Adjusted R-squared	-0.134386	S.D. dependent var	0.009719
S.E. of regression	0.010352	Akaike info criterion	-6.104173
Sum squared resid	0.005358	Schwarz criterion	-5.602391
Log likelihood	213.3856	Hannan-Quinn criter.	-5.906188
F-statistic	0.458441	Durbin-Watson stat	1.984306
Prob(F-statistic)	0.944325		

Heteroskedasticity Test: Breusch-Pagan-Godfrey

F-statistic	1.879446	Prob. F(10,54)	0.0686
Obs*R-squared	16.78204	Prob. Chi-Square(10)	0.0793
Scaled explained SS	20.54777	Prob. Chi-Square(10)	0.0245

Test Equation:
Dependent Variable: RESID^2
Method: Least Squares
Date: 11/18/17 Time: 13:55
Sample: 2001Q2 2017Q2
Included observations: 65

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	4.59E-05	3.28E-05	1.399843	0.1673
D(LNPEX(-1))	0.000894	0.002509	0.356221	0.7231
D(LNPEX(-2))	-0.002306	0.002860	-0.806290	0.4236
D(LNPEX(-3))	-0.006255	0.002525	-2.477101	0.0164
D(LNPIM(-1))	-0.000836	0.002906	-0.287537	0.7748
D(LNPIM(-2))	0.002510	0.003217	0.780429	0.4385
D(LNPIM(-3))	0.009170	0.002642	3.470729	0.0010
D(LNREER(-2))	-0.001720	0.002502	-0.687498	0.4947
D(LNITOT(-4))	0.001589	0.000603	2.635434	0.0109
COINTEQ02(-1)	-0.004891	0.002330	-2.099112	0.0405
D2	5.07E-06	0.000177	0.028673	0.9772

R-squared	0.258185	Mean dependent var	9.30E-05
Adjusted R-squared	0.120812	S.D. dependent var	0.000177
S.E. of regression	0.000166	Akaike info criterion	-14.42156
Sum squared resid	1.48E-06	Schwarz criterion	-14.05359
Log likelihood	479.7007	Hannan-Quinn criter.	-14.27637
F-statistic	1.879446	Durbin-Watson stat	1.914625
Prob(F-statistic)	0.068564		

Prilog 5

Parsimonious VEC-m1

d(lnpim) c d(lnpim(-1)) d(lnpim(-2)) d(lnpim(-3)) d(lnpim(-4)) d(lnpex(-1)) d(lnpex(-2)) d(lnpex(-3)) d(lnpex(-4)) d(lnreer(-1)) d(lnreer(-2)) d(lnreer(-3)) d(lnreer(-4)) d(lnitot(-1)) d(lnitot(-2)) d(lnitot(-3)) d(lnitot(-4)) cointeq01(-1) cointeq02(-1)

Dependent Variable: D(LNPIM)
Method: Least Squares
Date: 11/18/17 Time: 14:16
Sample (adjusted): 2001Q1 2017Q2
Included observations: 66 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.001782	0.001757	-1.014480	0.3145
D(LNPIM(-3))	0.183571	0.102517	1.790649	0.0785
D(LNREER(-1))	0.292427	0.147624	1.980890	0.0523
D(LNITOT(-2))	0.069161	0.031336	2.207055	0.0312
COINTEQ02(-1)	-0.358713	0.117348	-3.056843	0.0034
D1	0.012697	0.005343	2.376516	0.0207
D2	-0.023390	0.010103	-2.315145	0.0241

R-squared	0.329365	Mean dependent var	0.002755
Adjusted R-squared	0.261165	S.D. dependent var	0.011059
S.E. of regression	0.009506	Akaike info criterion	-6.373826
Sum squared resid	0.005331	Schwarz criterion	-6.141590
Log likelihood	217.3363	Hannan-Quinn criter.	-6.282059
F-statistic	4.829394	Durbin-Watson stat	1.946021
Prob(F-statistic)	0.000453		

Prilog 6

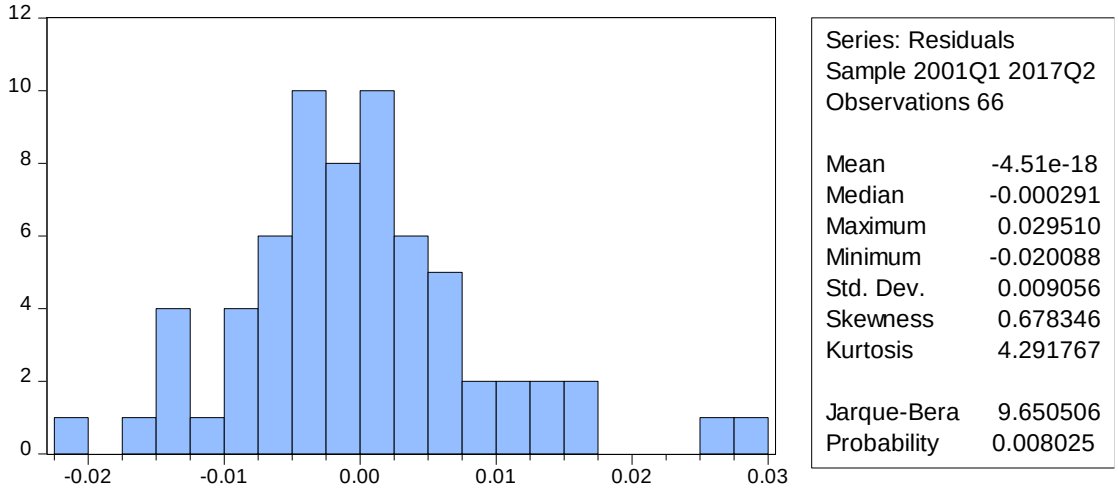
Date: 11/18/17 Time: 14:16
Sample: 2000Q1 2017Q2
Included observations: 66
Q-statistic probabilities adjusted for 6 dynamic regressors

Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob*
. | . |	. | . |	1	0.026	0.026	0.0469	0.829
. | . |	. | . |	2	-0.021	-0.022	0.0777	0.962
. | . |	. | . |	3	0.040	0.041	0.1935	0.979
. |*. |	. |*. |	4	0.115	0.113	1.1554	0.885

*Probabilities may not be valid for this equation specification.

Date: 11/18/17 Time: 14:17
Sample: 2000Q1 2017Q2
Included observations: 66

Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob
.*| . |	.*| . |	1	-0.094	-0.094	0.6140	0.433
.*| . |	.*| . |	2	-0.159	-0.169	2.3890	0.303
. | . |	.*| . |	3	-0.062	-0.100	2.6657	0.446
. | . |	. | . |	4	0.017	-0.030	2.6869	0.612



Breusch-Godfrey Serial Correlation LM Test:

F-statistic	0.390908	Prob. F(4,55)	0.8143
Obs*R-squared	1.824489	Prob. Chi-Square(4)	0.7680

Test Equation:
Dependent Variable: RESID
Method: Least Squares
Date: 11/18/17 Time: 14:17
Sample: 2001Q1 2017Q2
Included observations: 66
Presample missing value lagged residuals set to zero.

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.000534	0.001968	0.271307	0.7872
D(LNPIM(-3))	-0.123272	0.175576	-0.702098	0.4856
D(LNREER(-1))	-0.085175	0.176054	-0.483801	0.6304
D(LNITOT(-2))	-0.001491	0.033529	-0.044469	0.9647
COINTEQ02(-1)	-0.014669	0.128288	-0.114343	0.9094
D1	-0.002555	0.006190	-0.412824	0.6813
D2	-0.001119	0.010815	-0.103456	0.9180
RESID(-1)	0.044225	0.146188	0.302521	0.7634
RESID(-2)	-0.023713	0.150468	-0.157595	0.8754
RESID(-3)	0.190555	0.235326	0.809751	0.4216
RESID(-4)	0.158852	0.147800	1.074771	0.2872

R-squared	0.027644	Mean dependent var	-4.51E-18
Adjusted R-squared	-0.149148	S.D. dependent var	0.009056
S.E. of regression	0.009708	Akaike info criterion	-6.280647
Sum squared resid	0.005184	Schwarz criterion	-5.915705
Log likelihood	218.2614	Hannan-Quinn criter.	-6.136441
F-statistic	0.156363	Durbin-Watson stat	2.133568
Prob(F-statistic)	0.998380		

SAŽETAK

Hrvatska kao malo, otvoreno gospodarstvo svoj razvoj može temeljiti na uvjetima razmjene kao ključni faktor napretka. Uloga uvjeta razmjene ima značajan utjecaj na promjene izvoznih i uvoznih cijena. Relativne promjene cijena odražavaju se promjenama u uvjetima razmjene ali naravno u različitom smjerovima ovisno o strukturi izvoza i uvoza. Također, promjene u pogledu tečaja utječu na promjene u relativnim cijenama pa često nije jasno kako navedena kretanja utječu na ekonomiju i nacionalno gospodarstvo. Cilj ovog rada je utvrditi kakav utjecaj imaju uvjeti razmjene i realni efektivni tečaj na promjene izvoznih i uvoznih cijena dobara. Analiza se temelji na kvartalnim podacima za razdoblje od 2000. Q1 do 2017. Q2. Empirijski model rađen je prema Johansenovoj metodologiji za dugi rok, dok što se tiče kratkoročne ravnoteže, prikazana je uvjetnim VEC modelom. Rezultati kratkog roka su u skladu s dugoročnom analizom. Tako, prihodovni uvjeti razmjene dobra i uvozne cijene dobara su pozitivno povezane sa izvoznim cijenama dobara, dok negativno sa tečajem. S druge strane, izvozne cijene dobara i tečaj su pozitivno povezani sa uvoznim cijenama dobara, dok negativno sa prihodovnim uvjetima razmjene.

Ključne riječi: uvjeti razmjene, prihodovni uvjeti razmjene, izvozne i uvozne cijene, realni efektivni tečaj

SUMMARY

Croatia as a small, open economy can base its development one the terms of trade as a key factor of the progress. Terms of trade have a role in the significant impact on changes in export and import. Relative price changes are reflected in the structure of export and import through terms of trade. Also, as the change in the exchange rate affect on changes in relative prices, it is often unclear how they affect economy and national welfare. The goal of this paper is to determine the affect of terms of trade and real effective exchange rate on import and export prices for goods. The analysis is based on quarterly data for the period 2000. Q1 through 2017. Q2. Empirical model was estimated with the usage of Johansen cointegration method for the long–run and parsimonious vector error correction model for the short–run. The short–term results are consistent with long run–term analysis. Therefore, income terms of trade for goods and import prices for goods are positively related to export prices of goods and negatively related to the exchange rate. On the other hand, the export prices of the goods and exchange rate are positively related with import prices for goods and negatively related with income terms of trade.

Keywords: terms of trade, income terms of trade, export and import prices, real effective exchange rate.