UTJECAJ FINANCIJSKE INTEGRACIJE NA USKLAĐIVANJE POSLOVNOG CIKLUSA HRVATSKE SA ZEMLJAMA EUROZONE

Tolj, Ante

Doctoral thesis / Disertacija

2020

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:124:610066

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET

ANTE TOLJ

UTJECAJ FINANCIJSKE INTEGRACIJE NA USKLAĐIVANJE POSLOVNOG CIKLUSA HRVATSKE SA ZEMLJAMA EUROZONE

DOKTORSKA DISERTACIJA

Split, 2019.

SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET

POSLIJEDIPLOMSKI SVEUČILIŠNI STUDIJ
EKONOMIJE I POSLOVNE EKONOMIJE

Ante Tolj

UTJECAJ FINANCIJSKE INTEGRACIJE NA USKLAĐIVANJE POSLOVNOG CIKLUSA HRVATSKE SA ZEMLJAMA EUROZONE

DOKTORSKA DISERTACIJA

Mentor: Prof. dr. sc. Mario Pečarić

Split, 2019.

Pokojnom ocu Veselku

SAŽETAK

Financijskim integriranjem zemalja glavna prepreka formiranju optimalnog valutnog područja u Mundellovom (1961) modelu više nije problematična, čime financijska integracija postaje ključni čimbenik koji omogućava *ex post* stvaranje optimalnog valutnog područja.

Zbog mogućnosti da putem tržišnog mehanizma podjele rizika apsorbira asimetrične šokove te tako potakne usklađivanje poslovnih ciklusa, financijska integracija važna je u arhitekturi valutnih područja, kao i kod zemalja koje su u procesu monetarnog integriranja.

U skladu s teorijskim okvirom kreiran je empirijski model s ciljem određivanja smjera i intenziteta utjecaja financijske integracije na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone. Pri tome je poseban naglasak stavljen na neizravni utjecaj financijske integracije putem kanala specijalizacije i trgovinske integracije. Parametri modela procijenjeni su korištenjem panel analize. Usklađenost poslovnih ciklusa mjerena je Cerqueira-Martinsovim (2009) indeksom kojim su uklonjeni nedostatci korištenja Pearsonovog koeficijenta korelacije.

Rezultati istraživanja potvrđuju da kapitalni kanal nije dovoljno snažan da omogući visoki stupanj *ex ante* osiguranja, tj. spriječi pojavu idiosinkratskih šokova. Osim toga, potvrđuje se neučinkovitost kreditnog kanala za vrijeme financijskih poremećaja i kriza, tj. nemogućnost da se *ex post* apsorbiraju idiosinkratski šokovi i na taj način uskladi hrvatski poslovni ciklus s poslovnim ciklusima zemalja eurozone. Također, rezultati potvrđuju da financijska integracija potiče specijalizaciju koja u Hrvatskoj ide prema nerazmjenjivim sektorima. Na taj način smanjuje se sličnost sektorskih struktura Hrvatske i zemalja eurozone te one postaju osjetljivije na idiosinkratske šokove.

Zaključno, koncept valutnog područja temeljen isključivo na financijskoj integraciji je naivan te ga je potrebno nadopuniti drugim mehanizmima apsorpcije šokova, prvenstveno anticikličkom fiskalnom politikom.

Ključne riječi: *financijska integracija, usklađenost poslovnih ciklusa, sektorska specijalizacija, trgovinska integracija, konvergencija fiskalnih politika.*

SUMMARY

By integrating countries financially, the main obstacle to the formation of an optimal currency area in Mundell's (1961) model is no longer problematic, making financial integration a key factor that enables ex post creation of an optimal currency area.

Financial integration is important in currency area architecture as well as in countries undergoing monetary integration, because of the ability to absorb asymmetric shocks through a market-based risk-sharing mechanism, thereby fostering business cycle synchronization.

In accordance with the theoretical framework, an empirical model has been created with the aim of determining the direction and intensity of the impact of financial integration on business cycle synchronization of Croatia with the eurozone countries. Particular emphasis was placed on the indirect impact of financial integration through channels of specialization and trade integration. Model parameters were estimated using panel analysis. Business cycle synchronization was measured by the Cerqueira-Martins (2009) index, which eliminates disadvantages of using the Pearson correlation coefficient.

Results of the research confirm that the capital channel is not strong enough to allow a high degree of ex ante insurance, i.e. to prevent the occurrence of idiosyncratic shocks. In addition, the inefficiency of the credit channel during financial distortions and crises is confirmed, i.e. the inability to absorb idiosyncratic shocks ex-post and thereby synchronize the Croatian business cycle with the business cycles of the eurozone countries. Also, results confirm that financial integration induces specialization that moves to non-tradable sectors in Croatia. This way, the similarity of the sectoral structures of Croatia and the eurozone countries is reduced so they become more sensitive to idiosyncratic shocks.

In conclusion, the concept of a currency area based solely on financial integration is naive and needs to be complemented by other shock absorption mechanisms, primarily anti-cyclical fiscal policy.

Keywords: *financial integration, business cycle synchronization, sectoral specialization, trade integration, fiscal policy convergence*

SADRŽAJ

1. UVOD 1

1.1. Problem i predmet istraživanja 1
1.2. Ciljevi istraživanja 10
1.3. Istraživačke hipoteze 12
1.4. Metodologija znanstvenog istraživanja 18
1.5. Struktura rada 21

2. USKLAĐENOST POSLOVNIH CIKLUSA KAO META KRITERIJ TEORIJE OPTIMALNIH VALUTNIH PODRUČJA 23

2.1. Pojam i razvoj teorije optimalnih valutnih područja 23
2.2. Teorijski doprinosi teorije optimalnih valutnih područja 50
2.2.1. Hipoteza o endogenosti 50
2.2.2. Hipoteza o specijalizaciji 54
2.3. Pojam i važnost usklađenosti poslovnih ciklusa za provođenje zajedničke monetarne politike 55
2.3.1. Definiranje poslovnih ciklusa 60
2.3.2. Procjena poslovnih ciklusa 62
2.3.3. Mjere usklađenosti poslovnih ciklusa 69
2.3.4. Pregled dosadašnjih istraživanja usklađenosti poslovnih ciklusa 77

3. ZNAČAJ FINANCIJSKE INTEGRACIJE ZA MONETARNO INTEGRIRANJE 84

3.1. Pojam i definicija financijske integracije 84
3.2. Koristi i troškovi financijske integracije 88
3.2.1. Koristi financijske integracije 89
3.2.2. Troškovi financijske integracije 92
3.3. Važnost financijske integracije u procesu monetarnog integriranja 100
3.3.1. Učinkovita alokacija resursa 100
3.3.2. Podjela rizika i uglađivanje potrošnje 102
3.4. Mjerenje stupnja financijske integracije 104

4. UTJECAJ FINANCIJSKE INTEGRACIJE NA USKLAĐIVANJE POSLOVNIH CIKLUSA 111

4.1. Transmisijski kanali utjecaja financijske integracije na usklađivanje poslovnih ciklusa 111
4.2. Pregled istraživanja utjecaja financijske integracije na usklađivanje poslovnih ciklusa 120

5. EMPIRIJSKA ANALIZA UTJECAJA FINANCIJSKE INTEGRACIJE NA USKLAĐIVANJE POSLOVNOG CIKLUSA HRVATSKE SA ZEMLJAMA EUROZONE ... 123

5.1. Empirijski model istraživanja ... 123
5.2. Varijable i indikatori ... 127
5.2.1. Usklađenost poslovnih ciklusa ... 128
5.2.2. Financijska integracija ... 135
5.2.3. Trgovinska integracija ... 140
5.2.4. Sličnost sektorskih struktura ... 143
5.2.5. Konvergencija fiskalnih politika ... 146
5.3. Prostorna i vremenska definicija uzorka ... 150
5.4. Rezultati istraživanja ... 150
5.4.1. Deskriptivna statistika ... 151
5.4.2. Ekonometrijska panel analiza ... 160
6. ZAKLJUČNA RAZMATRANJA ... 211

6.1. Rasprava o rezultatima istraživanja ... 213
6.2. Doprinosi i implikacije rezultata istraživanja ... 218
6.3. Ograničenja istraživanja ... 221
6.4. Smjernice za buduća istraživanja ... 223
LITERATURA ... 225

POPIS GRAFIKONA ... 243

POPIS SLIKA ... 244

POPIS TABLICA ... 244

PRILOZI ... 245

ŽIVOTOPIS ... 253

1. UVOD

1.1. Problem i predmet istraživanja

Financijska deregulacija, liberalizacija međunarodnih tokova kapitala i razvoj informacijskih tehnologija devedesetih godina prošlog stoljeća omogućili su financijsko integriranje europskih zemalja, a cjelokupni proces popraćen je snažnim kretanjem kapitala. Hrvatska je, kao i ostala rastuća tržišta te rubne zemlje eurozone (Grčka, Portugal, Irska, Španjolska), u razdoblju od 2000. do 2008. godine ostvarila snažni rast kapitalnih priljeva s osnove izravnih stranih ulaganja i zaduživanja kod inozemnih kreditora[1]. Priljevu kapitala pridonijeli su čimbenici specifični za zemlju (engl. county-specific factors) poput privatizacije, stabilnog tečaja, visokih domaćih kamatnih stopa, makroekonomske stabilnosti, kao i povoljni globalni trendovi (engl. push factors) poput niskih kamatnih stopa u industrijaliziranim zemljama, rasta globalne likvidnosti i bankovnog kreditiranja privatnog sektora dolaskom stranih banaka (Otker-Robe i ostali, 2007).

Lakši pristup kapitalu potaknuo je veće stope rasta temeljene na snažnoj potražnji putem potrošnje i investicija. Abiad, Leigh i Mody (2007) ističu da je stabilan priljev kapitala u zemlje Središnje i Istočne Europe iz kapitalom obilnijih EU-15 potaknuo konvergenciju dohodaka, a upravo je to rezultat koji se očekuje od financijske integracije. Međutim, s pojavom globalne financijske krize te tijekom europske dužničke krize (od 2010. do 2012.) dolazi do naglog zastoja kapitalnih priljeva koji je prisilio zemlje da se podvrgnu snažnoj prilagodbi. Ispravljanje nagomilanih vanjskih neravnoteža u Hrvatskoj temeljilo se na smanjenju privatne i javne potrošnje, što je u konačnici uzrokovalo snažni pad proizvodnje i zaposlenosti.

Financijska integracija je širok pojam, a može se definirati s institucionalnog i legalnog aspekta (*de jure*) ili na činjeničnoj bazi (*de facto*). Baele i ostali (2004) ističu da su financijska tržišta *de jure* integrirana ako svi potencijalni sudionici tržišta imaju iste relevantne karakteristike: 1) suočavaju se s jedinstvenim skupom pravila kad se odluče koristiti s tim financijskim instrumentima i/ili uslugama; 2) imaju jednak pristup istom skupu financijskih instrumenata i/ili usluga; 3) tretirani su jednako kad su aktivni na tržištu. Iako je *de jure* financijska integracija

[1] Ukupni kapitalni priljevi iz inozemstva u Hrvatsku 2000. godine iznosili su 3 miljarde eura da bi kontinuirano rasli sve do 2008. godine u kojoj iznose 7.6 milijardi eura što iznosi 17% BDP-a (Ljubaj, Martinis i Mrkalj, 2010).

nužan, nije dovoljan preduvjet *de facto* financijske integracije. Naime, činjenica da je zemlja prihvatila mjere za provođenje financijske integracije ne znači da će se kapital kretati između zemalja. Stoga se mjerenje *de facto* financijske integracije (za razliku od *de jure* financijske integracije koja se mjeri stupnjem ograničenja na međunarodne transakcije i financijski račun bilance plaćanja) temelji na količinskim indikatorima koji mjere međunarodne kapitalne tokove i stanje (engl. stock) prekogranične financijske imovine i obveza; te cjenovnim indikatorima koji mjere odstupanja od zakona jedne cijene. U ovoj disertaciji pod pojmom financijske integracije smatrat će se *de facto* financijska integracija.

Literatura ističe niz koristi od financijskog integriranja zemalja. Osim pozitivnog utjecaja kapitalnih tokova na domaće investicije i rast, koristi financijske integracije proizlaze iz mogućnosti uglađivanja potrošnje, poboljšanja makroekonomske discipline, povećanja učinkovitosti bankarskog sustava i financijske stabilnosti (Agenor, 2003). S druge strane, financijska integracija stvara i određene troškove. Kroz povećani priljev kapitala financijska integracija uzrokuje ubrzanu monetarnu ekspanziju koja stvara inflatorni pritisak i negativno utječe na makroekonomsku stabilnost. Dalje, slobodno kretanje kapitala otežava kontrolu kamatnih stopa i deviznog tečaja te na taj način onemogućava provođenje vlastite monetarne politike. Osim toga, Agenor (2003) ističe da troškovi financijskog integriranja uključuju: visoki stupanj koncentracije kapitalnih tokova, slabiji pristup financiranju za manje zemlje, neodgovarajuću alokaciju kapitalnih tokova koja otežava rast i pojačava postojeće domaće distorzije, prociklično kretanje kratkoročnih kapitalnih tokova te visoki stupanj volatilnosti kapitalnih tokova.

Pristupanjem Europskoj uniji Hrvatska se obvezala uvesti euro kao službenu valutu, tj. postati članica eurozone. Temelj stabilnosti valutnog područja, tj. nužan uvjet za njegovo funkcioniranje predstavlja učinkovito upravljanje asimetričnim šokovima te zajedničkim šokovima koji različito pogađaju zemlje (šokovi s asimetričnom transmisijom). U tom kontekstu, u teoriji optimalnih valutnih područja istaknut je važan kriterij za monetarno integriranje - usklađenost poslovnih ciklusa (Gachter i ostali, 2012). Kod neusklađenih poslovnih ciklusa zemalja članica valutnog područja (što implicira pojavu navedenih šokova) zajednička monetarna politika pojedinim zemljama može stvoriti dodatne makroekonomske troškove. U takvoj situaciji zemljama je isplatljivije koristiti vlastitu monetarnu politiku koja je prilagođena njihovom poslovnom

ciklusu[2]. S druge strane, usklađeni poslovni ciklusi istovremeno se kreću kroz iste faze ciklusa ekonomske aktivnosti, tj. istovremeno prolaze kroz ekspanzije, recesije, usporavanja i ubrzanja ekonomske aktivnosti (Globan, 2018). U tom slučaju poslovni ciklusi imaju isti tajming, smjer i magnitudu, te omogućavaju središnjoj banci provođenje učinkovite monetarne politike (Antonakakis i Tondl, 2014). Stoga visoki stupanj usklađenosti indicira da će zajednička monetarna politika biti prikladna za sve zemlje članice (Artis, Marcellino i Proietti, 2003).

Fidrmuc i Korhonen (2006) ističu da se kriterij usklađenosti poslovnih ciklusa intenzivno primjenjuje prilikom analize koristi i troškova prihvaćanja eura kod novih zemalja članica EU. Iako je usklađenost poslovnih ciklusa zemalja EU analizirana u brojnim istraživanjima (Artis i Zhang, 1999; Fidrmuc i Korhonen, 2006; Darvas i Szapary, 2006; Bergman, 2006; Duran i Ferreira-Lopes, 2017; itd.), istraživanja koja u analizu uključuju poslovni ciklus Hrvatske još uvijek su relativno rijetka i uključuju tek nekoliko domaćih (Bellulo, Šonje i Vrbanc, 2000; Šonje i Vrbanc, 2000; Arčabić, 2011; Kotarac, Kunovac i Ravnik, 2017; Tomić i Demanuele, 2017; Arčabić, 2018) i stranih (Furceri i Karras, 2006; Obradović i Mihajlović, 2013; Gouveia, 2014; Hildebrandt i Moder, 2015) znanstvenih i stručnih radova.

Konceptualni model za analizu troškova i koristi monetarnog integriranja pruža teorija optimalnih valutnih područja (OCA). Osim usklađenosti poslovnih ciklusa navedena teorija ističe i financijsku integraciju kao jedan od ključnih čimbenika monetarnog integriranja. Ingram (1962) navodi da financijska integracija smanjuje potrebu za prilagodbom deviznog tečaja i omogućava apsorpciju privremenih negativnih poremećaja kroz kapitalne priljeve - pozajmljivanjem od suficitnih područja ili dekumulacijom neto strane imovine. S visokim stupnjem financijske integracije čak i male promjene kamatnih stopa pokrenut će ravnotežno kretanje kapitala između partnerskih zemalja što će smanjiti razlike u dugoročnim kamatnim stopama, olakšati financiranje vanjskih neravnoteža i potaknuti učinkovitu alokaciju resursa (Mongelli, 2008). Mobilnošću kapitala financijska integracija olakšava prilagodbu na nastale makroekonomske šokove jer omogućava zemljama da lakše povuku sredstva iz zajedničkog bazena štednje[3] (Jappelli i Pagano,

[2] Javlja se tzv. "jedna veličina ne odgovara svima" (engl. one size does not fit all) problem koji može ugroziti političku potporu za opstankom monetarne unije. Naime, zemlje koje se nalaze u silaznoj fazi poslovnog ciklusa preferiraju ekspanzivniju monetarnu politiku, dok zemlje koje se nalaze u uzlaznoj fazi poslovnog ciklusa preferiraju restriktivniju monetarnu politiku.

[3] Tako npr., ako se zemlja suoči s padom nacionalne štednje zbog povećanja javnog deficita, može lakše posegnuti za stranom štednjom da zadrži nivo nacionalnih investicija.

2008). Također, zemlje s većom mogućnošću rasta mogu realizirati dodatne investicije čak i ako domaća kućanstva ne povećaju štednju na odgovarajući način. Ako su tržišta kapitala integrirana, regije i zemlje se mogu osigurati od asimetričnih šokova i na taj način bolje iskoristiti komparativne prednosti koje proizlaze iz razlika u tehnologiji, dostupnosti faktora ili ekonomije obujma (Kalemli-Ozcan i ostali, 2003).

Financijskim integriranjem zemalja glavna prepreka formiranju optimalnog valutnog područja u Mundellovom (1961) modelu[4] nije više problematična jer nemobilni rad može zamijeniti mobilni kapital i time omogućiti vraćanje sustava u ravnotežu. Time financijska integracija postaje ključni čimbenik koji svojim endogenim djelovanjem omogućava *ex post* stvaranje optimalnog valutnog područja.

Zbog mogućnosti da putem tržišnog mehanizma podjele rizika (engl. risk sharing) apsorbira asimetrične šokove te na taj način potakne usklađivanje poslovnih ciklusa, financijska integracija predstavlja važan koncept u arhitekturi valutnih područja, kao i kod zemalja koje su u procesu monetarnog integriranja (poput Hrvatske). Cimadomo i ostali (2018) ističu dva osnovna kanala mehanizma tržišne podjele rizika: kreditni kanal i kapitalni kanal. Kapitalni kanal djeluje putem tržišta kapitala, a omogućava *ex ante* osiguranje od pojave idiosinkratskih šokova putem ukriženog prava vlasništva na imovinu, kamatu i rentu. S druge strane, kreditni kanal omogućava *ex post* prilagodbu na idiosinkratske šokove putem zaduživanja/pozajmljivanja na tržištu kredita. Međutim, Furceri i Zdziencika (2013) ističu da se putem kanala podjele rizika može ugladiti samo dio cikličke divergencije, a navedeni mehanizam osobito je neučinkovit kod pojave snažne recesije.

Podjela rizika nije jedini tržišni mehanizam putem kojeg financijska integracija utječe na apsorpciju asimetričnih šokova. Ruscher (2015) ističe još dva mehanizma: mehanizam relativne cijene (engl. relative price mechanism)[5] i mehanizam realne kamatne stope (engl. real interest rate mechanism). Promjene relativnih cijena predstavljaju važan mehanizam putem kojeg se zemlje eurozone prilagođavaju na asimetrične šokove. Naime, kod zemalja članica sa slabijom cikličkom pozicijom od ostatka unije troškovi rada i cijene opadaju u odnosu na ostatak unije. Posljedično poboljšanje realnog efektivnog deviznog tečaja pomaže ojačati cikličku poziciju

[4] Glavna prepreka je faktorska nemobilnost. U skladu s time Mundell (1961) definira optimalno valutno područje kao geografsku domenu unutar koje postoji faktorska mobilnost.
[5] Mehanizam relativne cijene u literaturi se često zove kanal konkurentnosti (engl. competitiveness channel).

zemalja putem učinaka na izvoz i supstituciju uvoza (Ruscher, 2015). S druge strane, mehanizam realne kamatne stope predstavlja prepreku stabilizacijskoj funkciji mehanizma relativne cijene. Promjene relativnih cijena također utječu na realne kamatne stope. Tako npr., kod zemalja članica koje ostvaruju snažniji porast potražnje, inflacija snažnije raste u odnosu na ostatak unije. S obzirom na zajedničku nominalnu kamatnu stopu, viša inflacija implicira nižu realnu kamatnu stopu koja dodatno pojačava potražnju[6]. U pojedinim zemljama niže realne kamatne stope potaknule su kreditni bum koji je pojačao privatnu potrošnju i generirao deficite tekućeg računa bilanci plaćanja. S druge strane, realne kamatne stope kod zemalja s nižom inflacijom ograničile su domaću potražnju i dovele do stvaranja suficita tekućeg računa bilanci plaćanja. Snažno povećanje prekograničnih kapitalnih tokova i financijske imovine djelovalo je destabilizirajuće na eurozonu (Ederer, 2015). Kuenzel i Ruscher (2013) ističu da su negativne posljedice financijskog integriranja eurozone podcijenjene.

Kao jedan od glavnih uzročnika stvaranja vanjskih neravnoteža u eurozoni literatura ističe pad konkurentnosti u perifernim zemljama koji je posljedica pretjeranog rasta jediničnih troškova rada (engl. unit labour cost) u odnosu na rast produktivnosti. Osim toga, neravnoteže su djelomično rezultat preoptimističnih očekivanja konvergencije, a odražavaju i nedovoljne reforme tržišta rada. S druge strane, Sanchez i Varoudakis (2013) navode da se poboljšanje konkurentnosti i tekućeg računa bilanci plaćanja zemalja jezgre temeljilo na ograničavanju plaća (engl. wage moderation). Međutim, vanjske neravnoteže i promjene u konkurentnosti mogu se događati istovremeno, ali mogu biti uzrokovane drugim čimbenicima, stoga ne reflektiraju nužno uzročno-posljedičnu vezu. Sanchez i Varoudakis (2013) ističu rast domaće potražnje potaknut financijskom integracijom kao ključni uzrok stvaranja vanjskih neravnoteža u eurozoni. Koristeći stilizirani model tekućeg računa i ravnoteže tržišta dobara Wyplosz (2013) potvrđuje da šokovi potražnje velikim djelom objašnjavaju neravnoteže tekućih računa u eurozoni, dok šokovi konkurentnosti imaju malu eksplanatornu moć.

Schmitz i Hagen (2011) ističu da nastale neravnoteže u eurozoni ne predstavljaju neodgovarajuću makroekonomsku prilagodbu već znak njezinog ispravnog funkcioniranja. Ipak, potrebno je razlikovati "dobre neravnoteže" koje potiču konvergenciju putem većih investicija u sektor razmjenjivih dobara i rastom produktivnosti od "loših neravnoteža" kod kojih se kapitalni tokovi

[6] Navedeni destabilizirajući mehanizam poznat je i kao „Waltersova kritika".

koncentriraju u nerazmjenjivom sektoru i potiču rast koji je dugoročno neodrživ jer ne generira izvoz potreban za otplatu dugova. U tom kontekstu posebno su problematične neravnoteže koje proizlaze iz pretjerane domaće potražnje[7]. Prije ili kasnije takva potražnja mora biti apsorbirana kroz njezino smanjivanje i posljedično ekonomsku kontrakciju jer zemlja treba generirati štednju potrebnu za otplatu dugova akumuliranih tijekom ekspanzije (Sanchez i Varoudakis, 2013).

Osim na potražnju kapitalni tokovi utječu i na realni efektivni devizni tečaj[8]. Važnu ulogu u navedenom utjecaju ima struktura kapitalnih tokova, pri čemu empirijska istraživanja potvrđuju da snažniji učinak na aprecijaciju tečaja ima priljev dugovnog kapitala nego vlasničkih investicija[9] (Davis, 2015). Iako su u razdoblju od 2001. do 2016. godine vlasničke investicije (uglavnom izravne strane investicije) bile važan izvor financiranja u Hrvatskoj, domaća ekonomija ipak se više oslanjala na dugovni kapital[10] (Bukovšak i ostali, 2017). Financijska integracija (i rezultirajući priljev kapitala) uzrokovala je aprecijaciju realnog efektivnog deviznog tečaja perifernih zemalja eurozone, a isto se dogodilo i u Hrvatskoj prije krize zbog bržeg rasta domaćih cijena u odnosu na strane cijene. Giavazzi i Spaventa (2010) ističu da aprecijacija realnog deviznog tečaja pogoršava konkurentnost razmjenjivog sektora što u konačnici doprinosi koncentraciji kapitalnih priljeva u nerazmjenjivim sektorima. U takvoj situaciji mijenjaju se sektorske strukture zemalja, tj. dolazi do njihove specijalizacije.

Negativni učinak specijalizacije pojavljuje se u situaciji kad se sektorska struktura zemlje pomiče od razmjenjivih prema nerazmjenjivim sektorima. Benigno i Fornaro (2014) ističu da su razmjenjivi sektori motor rasta ekonomije, a produktivnost raste s povećanjem udjela radnika zaposlenih u razmjenjivim sektorima. Nerazmjenjivi sektori imaju manju produktivnost od razmjenjivih sektora što dugoročno može smanjiti potencijal rasta i onemogućiti realnu konvergenciju zemalja. U tom kontekstu ključnu ulogu ima financijska integracija koja putem aprecijacije realnog efektivnog deviznog tečaja (i posljedično pada konkurentnosti) pridonosi istiskivanju proizvodnih i izvoznih aktivnosti zemlje, tj. njezinu specijalizaciju prema nerazmjenjivim sektorima.

---

[7] Pozitivni šokovi strane potražnje nisu problematični jer smanjuju deficit tekućeg računa.

[8] Utjecaj kapitalnih tokova na realni efektivni devizni tečaj može biti putem nominalne promjene u sustavu fluktuirajućih deviznih tečajeva, putem povećanja cijena u sustavu fiksnih deviznih tečajeva ili njihovom kombinacijom u sustavu intermedijarnih deviznih tečajeva.

[9] Vlasničke investicije češće su usmjerene u razmjenjive sektore što smanjuje pritisak na cijene u nerazmjenjivim sektorima.

[10] Priljev dugovnog kapitala u navedenom razdoblju iznosio je 54% ukupnih priljeva.

Brojni teorijski modeli (Saint-Paul, 1992; Acemoglu i Zilibotti, 1997; Feeney, 1999) i sl.) potvrđuju da financijska integracija inducira specijalizaciju u proizvodnji, a navedni utjecaj empirijski potvrđuju Basile i Girardi (2009) na uzorku 144 NUTS 2 regije koje pripadaju zemljama EU15. Obstfeld (1994) ističe da financijska integracija pomiče investicije prema rizičnijim projektima što omogućava zemljama da se specijaliziraju u skladu s komparativnim prednostima. Krugman (1993) ističe da veći stupanj integracije tržišta putem ekonomije obujma i učinaka aglomeracije potiče daljnju specijalizaciju koja zemlje čini osjetljivijima na tehnološke šokove i šokove potražnje. Zbog slabije diversifikacije outputa u slučaju specijalizacije, veći je rizik od pojave sektorski specifičnih (idiosinkratskih) šokova koji smanjuju usklađenost poslovnih ciklusa i otežavaju provođenje zajedničke monetarne politike.

Osim specijalizacije, u dostupnoj literaturi ističe se i kanal trgovinske integracije kao još jedan neizravni kanal utjecaja financijske integracije na usklađivanje poslovnih ciklusa - (Xing i Abbott, 2007; Dees i Zorel, 2012; Antonakakis i Tondl, 2014). Trgovinska integracija generira učinke na strani potražnje (Keynesov multiplikator), tj. utječe na jače prelijevanje šokova potražnje iz jedne zemlje u drugu povećavajući na taj način usklađenost njihovih poslovnih ciklusa. Frankel i Rose (1998) pronalaze pozitivan utjecaj trgovinske integracije na usklađivanje poslovnih ciklusa, a njihovi rezultati potvrđeni su u brojnim istraživanjima: Kose, Prasad i Terones (2003), Traistaru (2004), Abbott, Easaw i Xing (2008), Siedschlag i Tondl (2011), Gouveia i Correia (2013), Antonakakis i Tondl (2014), Alimi (2015) te Duran i Ferreira Lopes (2017). Financijska integracija utječe na trgovinsku integraciju putem tri osnovna transmisijska kanala: vertikalnih izravnih stranih investicija (Helpman, 1984), horizontalnih izravnih stranih investicija Markusen i Venables (2000) i trgovinskih kredita (Aizenman i Noy, 2009).

Rezultati dosadašnjih istraživanja utjecaja financijske integracije na usklađivanje poslovnih ciklusa značajno ovise o uzorku zemalja, promatranom vremenskom razdoblju te izabranom indikatoru financijske integracije i korištenoj mjeri usklađenosti poslovnih ciklusa.
Kose, Prasad i Terrones (2003) potvrđuju da financijska integracija (mjerena restrikcijama na transakcije kapitalnog računa i akumuliranim bruto kapitalnim tokovima) pojačava globalna prelijevanja makroekonomskih fluktuacija i na taj način potiče usklađivanje poslovnih ciklusa 76 zemalja u razdoblju od 1960. do 1999. godine.

Imbs (2004) pronalazi pozitivan utjecaj financijskih poveznica na usklađivanje poslovnih ciklusa 24 razvijene zemlje u razdoblju od 1980. do 2000. godine. Osim toga, identificira i neizravni utjecaj financijske integracije putem specijalizacije koji uzrokuje divergenciju poslovnih ciklusa. Ističe da utjecaj putem izravnih kanala financijske integracije dominira nad neizravnim kanalima.

S druge strane, Xing i Abbott (2007) potvrđuju da financijska integracija uzrokuje divergenciju poslovnih ciklusa 15 OECD zemalja u razdoblju od 1984. do 2003. godine, a osim izravnog utjecaja identificiraju i neizravni utjecaj financijske integracije putem trgovinske integracije i specijalizacije.

Slično njima, Garcia-Herrero i Ruiz (2008) analiziraju utjecaj financijske integracije na usklađivanje poslovnog ciklusa Španjolske (kao benchmark zemlje) s EU, G7 te zemljama Latinske Amerike (ukupno 109 zemalja). Pokazuju da financijska integracija (mjerena bilateralnim financijskim tokovima) negativno utječe na usklađivanje poslovnih ciklusa između Španjolske i navedenih zemalja. Zaključuju da financijska integracija potiče lakši transfer sredstava koji omogućava divergenciju poslovnih ciklusa što je i predviđeno standardnim modelom međunarodnih poslovnih ciklusa.

Isti (negativni) utjecaj potvrđuju i Kalemli-Ozcan, Papaioannou i Peydro (2013) na uzorku 18 razvijenih zemalja (u razdoblju od 1978. do 2006. godine), a kao glavni razlog ističu djelovanje šokova produktivnosti. Akin (2012) pronalazi da financijska integracija nema značajan utjecaj na usklađivanje poslovnih ciklusa 51 zemlje (od čega 27 rastućih ekonomija) u razdoblju od 1970. do 2008. godine.

Slično Akinu (2012), Dees i Zorell (2012) potvrđuju da financijska integracija nema značajan izravni utjecaj na usklađivanje poslovnih ciklusa 56 OECD i EU zemalja. Autori ističu da je utjecaj neizravan i realizira se putem konvergencije proizvodnih struktura koja potiče usklađivanje poslovnih ciklusa.

Konačno, Antonakakis i Tondl (2014) zaključuju da financijska integracija (mjerena udjelom bilateralnih izravnih stranih investicija u sumi BDP-ova parova zemalja) ima negativan izravni utjecaj na usklađivanje poslovnih ciklusa zemalja EU zbog dominacije investicija motiviranih osvajanjem novih tržišta (engl. market-seeking) koje traže prinos i diversifikaciju rizika na tržištima s različitim stopama rasta. Također, pronalaze pozitivan neizravni utjecaj financijske integracije na usklađivanje poslovnih ciklusa putem trgovinske integracije i specijalizacije zbog dominacije vertikalnih izravnih stranih investicija koje slijede komparativne prednosti.

Najveći dio navedenih istraživanja obuhvaća pretkrizno razdoblje, a pojava krize značajno je utjecala na obujam i strukturu kapitalnih tokova te ukazala na određena ograničenja i nedostatke financijske integracije koji su u teoriji optimalnih valutnih područja zanemareni. Osim toga, istraživanja su provedena uglavnom na uzorku razvijenih zemalja, dok je analiza za Hrvatsku u kontekstu navedenog problema zanemarena.

Dakle, iako se u teoriji optimalnih valutnih područja ističe važnost financijske integracije i usklađenosti poslovnih ciklusa kao ključnih preduvjeta (kriterija) za monetarno integriranje, empirijska istraživanja potvrđuju da njihov odnos nije jednoznačan. Utjecaj financijske integracije na usklađivanje poslovnih ciklusa realizira se putem nekoliko izravnih i neizravnih kanala koji nemaju isti smjer djelovanja. Naime, pojedini kanali međusobno se pojačavaju, ali i potiskuju. Osim toga, kanali utjecaja specifični su s obzirom na oblik kapitala Ako je utjecaj financijske integracije na usklađivanje poslovnih ciklusa negativan, onda financijska integracija otežava provođenje zajedničke monetarne politike zemalja eurozone, tj. povećava troškove monetarnog integriranja (za zemlje poput Hrvatske). Dodatno, kapitalni zastoji (engl. sudden stops) u kriznim vremenima potvrđuju naivnost modela funkcioniranja valutnih područja temeljenih na konceptu financijske integracije. Time se ujedno otvara pitanje što napraviti po pitanju financijske integracije, tj. čime nadopuniti njezino djelovanje.

Problem istraživanja posebno je značajan kad se promatra Hrvatska u odnosu na zemlje eurozone jer financijska integracija predstavlja važan kanal transmisije poslovnih ciklusa i mehanizam apsorpcije asimetričnih šokova, a Hrvatska većinu kapitalnih tokova ostvaruje upravo sa zemljama eurozone. Na temelju analize međuodnosa financijske integracije i usklađenosti poslovnih ciklusa dobit će se važne implikacije za vođenje hrvatske makroekonomske politike u uvjetima liberaliziranih kapitalnih tokova. Poznavanje izvora (ne)usklađenosti poslovnih ciklusa važno je i zbog bolje međunarodne koordinacije hrvatske ekonomske politike (male otvorene ekonomije) sa zemljama okruženja kako bi se olakšao i ubrzao njezin oporavak uslijed velikih poremećaja i kriza.

Osim toga, usklađenost poslovnog ciklusa Hrvatske s poslovnim ciklusima zemalja eurozone te visoki stupanj integracije njihovih financijskih tržišta fundamentalni su preduvjeti za učinkovito provođenje zajedničke monetarne politike. Analiza makroekonomskih troškova uvođenja eura za

Hrvatsku temelji se na upravo na međuodnosu financijske integracije i usklađenosti poslovnog ciklusa Hrvatske sa zemljama eurozone.

U skladu s navedenim problemom definira se i predmet istraživanja ove disertacije: utjecaj financijske integracije na usklađivanje poslovnih ciklusa uzimajući u obzir izravne i neizravne kanale, posebice između Hrvatske i zemalja eurozone.

Također, postavlja se nekoliko istraživačkih pitanja:

- Koji su nedostaci i ograničenja teorije optimalnih valutnih područja kao konceptualnog okvira za promišljanje o koristima i troškovima monetarnog integriranja?
- Kolika je važnost financijske integracije i usklađenosti poslovnih ciklusa za preuzimanje zajedničke valute te kakav je njihov međuodnos?
- Kojim kanalima financijska integracija utječe na usklađivanje poslovnih ciklusa? Postoje li osim izravnih kanala i neizravni kanali te kakav je njihov utjecaj?
- Kakve implikacije za monetarno integriranje Hrvatske i provođenje makroekonomske politike proizlaze iz utjecaja financijske integracije na usklađenost poslovnih ciklusa?

1.2. Ciljevi istraživanja

U skladu s problemom i predmetom istraživanja definirani su i ciljevi ovog istraživanja. Osnovni cilj istraživanja je kreirati empirijski model utjecaja financijske integracije na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone, tj. odrediti u kojem smjeru i kojim intenzitetom financijska integracija utječe na usklađivanje poslovnog ciklusa Hrvatske s poslovnim ciklusima zemalja eurozone uzimajući u obzir izravne i neizravne utjecaje.

U svrhu ostvarenja osnovnog cilja istraživanja definira se i nekoliko pomoćnih ciljeva:

1) kritički analizirati teoriju optimalnih valutnih područja – teorija optimalnih valutnih područja pruža konceptualni okvir za procjenu koristi i troškova monetarnog integriranja. Međutim, iako je imala snažan utjecaj na razvoj znanstvene misli, teorija optimalnih valutnih područja ima niz slabosti i ograničenja. U ovoj disertaciji prikazan je razvoj teorije optimalnih valutnih područja te su kritički analizirani kriteriji koje navedena teorija ističe (dio tih kriterija predstavlja varijable u

modelu utjecaja). Osim toga, istaknuta su ograničenja teorije koja su važna sa stajališta monetarnog integriranja i uspješnog funkcioniranja valutnog područja;

2) procijeniti poslovne cikluse Hrvatske i zemalja eurozone - analiza usklađenosti poslovnih ciklusa u prvom redu zahtijeva procjenu poslovnih ciklusa. U dosadašnjim istraživanjima korištene se različite metode procjene poslovnih ciklusa koje imaju određena ograničenja. Stoga su u ovoj disertaciji kritički analizirane metode procjene poslovnih ciklusa i izabrana metoda koja, u skladu s problemom i predmetom istraživanja, daje optimalne rezultate;

3) izabrati mjeru usklađenosti poslovnih ciklusa i utvrditi stupanj usklađenosti poslovnog ciklusa Hrvatske sa zemljama eurozone - u istraživanjima ovakvog tipa (koja su većinom rađena s presječnim podacima čime se zanemaruje vremenska dimenzija) koristi se nekoliko mjera usklađenosti poslovnih ciklusa. U tom kontekstu, jedan od pomoćnih ciljeva je sistematizirati i kritički analizirati mjere usklađenosti poslovnih ciklusa te izabrati mjeru usklađenosti poslovnih ciklusa koja je prilagođena panel analizi.

4) Teorija optimalnih valutnih područja ističe usklađenost poslovnih ciklusa kao meta kriterij monetarnog integriranja. U ovom istraživanju utvrdit će se stupanj usklađenosti poslovnog ciklusa Hrvatske sa zemljama eurozone jer je takva analiza neophodna u sklopu procjene makroekonomskih troškova prihvaćanja eura za Hrvatsku;

5) izabrati mjeru financijske integracije i utvrditi stupanj financijske integracije Hrvatske sa zemljama eurozone - sveobuhvatnu mjeru financijske integracije vrlo je teško razviti jer bi ona trebala uključiti sva financijska tržišta, tj. oblike kapitala. U istraživanjima ovakvog tipa najčešće se koriste cjenovno ili količinski orijentirane mjere, a obje mjere imaju određene prednosti i nedostatke. Osim toga, podaci za Hrvatsku (na bilateralnoj razini) su teško dostupni. U ovoj disertaciji dat će se prikaz korištenih mjera financijske integracije i njihova kritička analiza, te izabrati odgovarajući indikator i mjeru financijske integracije uzimajući u obzir ograničenja dosadašnjih istraživanja i ograničenja dostupnosti podataka za Hrvatsku;

6) Istražiti odrednice usklađenosti poslovnih ciklusa Hrvatske sa zemljama eurozone – da bi se ispravno odredila veličina i smjer utjecaja financijske integracije na usklađivanje poslovnih ciklusa, potrebno je istražiti te u analizu uključiti i ostale odrednice usklađenosti poslovnih ciklusa.

7) Objasniti utjecaj financijske integracije na usklađivanje poslovnih ciklusa – utjecaj financijske integracije na usklađivanje poslovnih ciklusa teorijski nije jednoznačan zbog djelovanja nekoliko (izravnih i neizravnih) transmisijskih kanala koji imaju suprotne učinke. U ovoj disertaciji sistematizirat će se i razjasniti osnovni transmisijski kanali utjecaja financijske integracije na usklađivanje poslovnih ciklusa kako bi se dobio kvalitetniji uvid u ovo poprilično kompleksno djelovanje;

8) Analizirati suodnos financijske integracije, trgovinske integracije i sličnosti sektorskih struktura sagledavajući Hrvatsku i zemlje eurozone – teorija ističe, a istraživanja potvrđuju međuovisnost financijske integracije, trgovinske integracije i sličnosti sektorskih struktura. Navedena analiza omogućava identifikaciju izravnog i neizravnog utjecaja financijske integracije na usklađivanje poslovnih ciklusa. Promatranje problema u kontekstu Hrvatske i zemalja eurozone omogućava njegovo sagledavanje iz perspektive Hrvatske što u dosadašnjim istraživanjima nije rađeno;

9) Konceptualno procijeniti makroekonomske troškove preuzimanja eura za Hrvatsku – s obzirom na to da većina kapitalnih tokova u Hrvatsku dolazi iz eurozone, u skladu s rezultatima provedenog istraživanja, procijenit će se makroekonomski troškovi preuzimanja eura, a koji proizlaze iz manjkavosti koncepta financijske integracije.

1.3. Istraživačke hipoteze

Empirijski dio istraživanja provest će se testiranjem tri temeljene istraživačke hipoteze. U skladu s problemom, predmetom i ciljevima istraživanja, definiraju se sljedeće istraživačke hipoteze:

H1: Financijska integracija izravno pozitivno utječe na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone.

Prema Davisu (2014) utjecaj financijske integracije na usklađivanje poslovnih ciklusa ovisi o utjecaju dva osnovna transmisijska kanala koji imaju suprotan smjer djelovanja – učinak bilance i učinak blagostanja.

Učinak bilance posljedica je djelovanja mehanizma međunarodnog financijskog multiplikatora (Krugman, 2008). Naime, negativni (financijski) šok u inozemstvu utječe na bilance domaćih banaka koje, suočene s povećanim gubitkom od stranog kreditnog portfelja, osim ponude stranih kredita smanjuju i ponudu kredita prema domaćim zajmoprimcima. Smanjenje ponude domaćih kredita uzrokuje pad domaće proizvodnje i u konačnici potiče konvergenciju poslovnih ciklusa promatranih zemalja. Učinak bilance karakterističan je za integrirano tržište kredita.
S druge strane, učinak blagostanja standardni je mehanizam u teoriji realnih poslovnih ciklusa. Putem učinka blagostanja visoko mobilni kapital kreće se od jedne zemlje prema drugoj loveći pri tome najveći povrat. U tom procesu pojačava utjecaj asimetričnih (tehnoloških) šokova koji uzrokuju divergenciju poslovnih ciklusa zemalja. Za razliku od učinka bilance, učinak blagostanja karakterističan je za integrirano tržište kapitala.

Davis (2014) ističe da učinak bilance ne djeluje na poslovne cikluse isključivo na integriranom tržištu kapitala, niti učinak blagostanja djeluje isključivo na integriranom tržištu kredita, već učinak blagostanja dominira nad učinkom bilance na integriranom tržištu kapitala i obrnuto, učinak bilance dominira nad učinkom bogatstva na integriranom tržištu kredita.

S obzirom na to da su ostala ulaganja prevladavajući oblik kapitalnih priljeva (koji čine većinu kapitalnih tokova) iz zemalja eurozone u Hrvatsku, pretpostavka je da dominacija kanala bilance (u odnosu na kanal blagostanja) potiče usklađivanje poslovnog ciklusa Hrvatske prema poslovnim ciklusima zemalja eurozone. Dakle, visoka ovisnost Hrvatske o kapitalnim tokovima iz zemalja eurozone čini je osjetljivom na poslovne cikluse zemalja eurozone. Negativni i pozitivni šokovi iz zemalja eurozone snažnije i brže se prenose na Hrvatsku putem financijske integracije i usklađuju poslovni ciklus Hrvatske s poslovnim ciklusima zemalja eurozone.

Osim putem transmisije poslovnih ciklusa (šokova), financijska integracija utječe na usklađivanje poslovnih ciklusa apsorpcijom idiosinkratskih šokova putem mehanizma tržišne podjela rizika. Cimadomo i ostali (2018) ističu dva osnovna kanala mehanizma tržišne podjele rizika: kreditni kanal i kapitalni kanal. Kapitalni kanal djeluje putem tržišta kapitala, a omogućava *ex ante* osiguranje od pojave idiosinkratskih šokova putem ukriženog prava vlasništva na imovinu, kamatu i rentu. S druge strane, kreditni kanal omogućava *ex post* prilagodbu na idiosinkratske šokove putem zaduživanja/pozajmljivanja na tržištu kredita.

Snažni kapitalni tokovi (u slučaju Hrvatske priljevi) omogućeni financijskom integracijom, dovode do jačeg uglađivanja dohotka (tj. manje mogućnosti pojave idiosinkratskih šokova) i potrošnje (lakše prilagodbe na idiosinkratske šokove) što u konačnici potiče usklađivanje poslovnog ciklusa Hrvatske s poslovnim ciklusima zemalja eurozone.

Pozitivan utjecaj financijske integracije na usklađivanje poslovnih ciklusa potvrđuju Kose, Prasad i Terrones (2003), Imbs (2004), Jansen i Stokman (2004), Schiavo (2008) te Davis (2014).

H2: Financijska integracija putem specijalizacije neizravno negativno utječe na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone.

Krugman (1993) ističe da veći stupanj tržišne integracije potiče divergenciju sektorskih struktura zemalja i divergenciju njihovih stopa rasta. Važna implikacija Krugmanove hipoteze o specijalizaciji (Krugman, 1993) je činjenica da integracija uzrokuje divergenciju poslovnih ciklusa i udaljava zemlje od optimalnog valutnog područja. Hipoteza H2 dijeli se na dvije pomoćne hipoteze H21 i H22.

H21: Financijska integracija potiče specijalizaciju koja uzrokuje divergenciju sektorskih struktura Hrvatske i zemalja eurozone.

Brojni teorijski modeli (Saint-Paul, 1992; Acemoglu i Zilibotti, 1997; Feeney, 1999) ističu da financijska integracija inducira specijalizaciju u proizvodnji. Kalemli-Ozcan i ostali (2003) navode da financijska integracija inducira veću specijalizaciju u proizvodnji zbog boljeg prekograničnog osiguranja prihoda. Obstfeld (1994) ističe da financijska integracija pomiče investicije prema rizičnijim projektima što omogućava zemljama da se specijaliziraju u skladu s komparativnim prednostima.
Dakle, općenito gledano, financijska integracija omogućava zemljama da se specijaliziraju u proizvodnji s ciljem iskorištavanja komparativnih prednosti (koje proizlaze iz tehnologije/faktorske raspoloživosti) ili ekonomije obujma.

Financijska integracija potaknula je snažne priljeve kapitala iz zemalja eurozone koji su u Hrvatskoj uzrokovali relativno brži rast domaćih cijena (i plaća) u odnosu na strane cijene.

Bukovšak i ostali (2017) ističu da se navedene promjene očituju u aprecijaciji realnog efektivnog deviznog tečaja.

Navedena aprecijacija pridonosi istiskivanju proizvodnih i izvoznih aktivnosti, tj. dolazi do pomaka od razmjenjivih prema nerazmjenjivim sektorima. Takva dinamika uzrokuje specijalizaciju hrvatske ekonomije i to prema sektorima koji imaju manju produktivnost jer su manje izloženi pritisku strane konkurencije (za razliku od razmjenjivih sektora).

H22: Razlike u sektorskim strukturama Hrvatske i zemalja eurozone negativno utječu na usklađivanje njihovih poslovnih ciklusa.

Sektorska struktura zemlje određuje njezinu reakciju kod pojave šokova (i u konačnici dinamiku poslovnih ciklusa). U tom kontekstu, zemlje slične kompozicije sektorskih struktura imaju sličnije reakcije kod pojave zajedničkih šokova. Slično tome, sektorski specifični šokovi jednako ih pogađaju zbog iste izloženosti njihovih sektora navedenoj vrsti šokova. Obrnuto, zemlje čija se kompozicija sektora značajno razlikuje imaju različite reakcije kod pojave zajedničkog šoka, a sektorski specifični šokovi ih različito pogađaju.

Strogo teorijski gledano, specijalizacija (koja uzrokuje divergenciju sektorskih struktura) se ne mora nužno negativno odraziti na usklađenost poslovnih ciklusa, ali u tom slučaju moraju postojati mehanizmi koji savršeno apsorbiraju idiosinkratske šokove (i zajedničke šokove s asimetričnim učincima).

S obzirom da dosadašnja istraživanja pokazuju da u Hrvatskoj postoji rigidnost cijena i plaća (Kunovac i Pufnik, 2015), ograničenja u provođenju fiskalne politike (Šimović, Ćorić i Deskar-Škrbić, 2014), a kanali podjele rizika na razini eurozone (za Hrvatsku ne postoje takva istraživanja) nisu dovoljno snažni za potpunu apsorpciju idiosinkratskih šokova (Cimadomo i ostali, 2018; Furceri i Zdzienicka, 2015; Afonso i Furceri, 2008; Asdrubali i ostali, 1996) osnovna pretpostavka je da sektorska specijalizacija uzrokuje divergenciju poslovnog ciklusa Hrvatske i poslovnih ciklusa zemalja eurozone jer čini promatrane zemlje osjetljivijima na idiosinkratske (asimetrične) šokove. Također, zajednički šokovi različito se odražavaju na Hrvatsku i na zemlje eurozone te na taj način negativno utječu na usklađivanje njihovih poslovnih ciklusa.

Osim toga, sektorska struktura važna je radi ostvarivanja većih stopa rasta. Benigno i Fornaro (2014) ističu da su razmjenjivi sektori motor rasta, i da se produktivnost povećava s povećanjem udjela radnika zaposlenih u razmjenjivim sektorima. Kretanjem specijalizacije u Hrvatskoj prema nerazmjenjivim sektorima smanjuje se njezina produktivnost, tj. dolazi do divergentnih stopa rasta Hrvatske i zemalja eurozone te se na taj način smanjuje usklađenost njihovih poslovnih ciklusa.

Imbs (2004) potvrđuje da financijska integracija potiče specijalizaciju zemalja u različitim sektorima i na taj način smanjuje usklađenost njihovih poslovnih ciklusa. Negativan utjecaj financijske integracije na usklađivanje poslovnih ciklusa putem specijalizacije također potvrđuju Xing i Abbott (2007), Garcia-Herrero i Ruiz (2008), Cerqueira i Martins (2009), Lee i Azali (2010) te Kalemli-Ozcan, Papaioannou i Peydro (2013).

H3: Financijska integracija neizravno pozitivno utječe na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone kroz jačanje trgovinske integracije.

Navedena hipoteza se zbog svoje složenosti dijeli na dvije pomoćne hipoteze: H31 i H32.

H31: Financijska integracija potiče trgovinsku integraciju Hrvatske sa zemljama eurozone.

Financijska integracija utječe na trgovinsku integraciju putem nekoliko transmisijskih kanala. Kanal vertikalnih izravnih stranih investicija omogućava multinacionalnim kompanijama razdvajanje poslovnih aktivnosti prema fazama proizvodnog procesa. Na taj način iskorištavaju se troškovne prednosti zemalja (Helpman, 1984). Vertikalne izravne strane investicije djeluju komplementarno na trgovinu i kao takve potiču trgovinsku integraciju zemalja. S druge strane, horizontalne izravne strane investicije nastaju kad postoje sličnosti u veličini tržišta i raspoloživosti faktora proizvodnje, a ostvaruju uštede na troškovima izvoza, osiguravaju kraće vrijeme isporuke i blizinu tržišta koja omogućava bržu prilagodbu i udovoljavanje zahtjevima potrošača. U tom kontekstu, horizontalne izravne strane investicije predstavljaju zamjenu za postojeće trgovinske tokove (Markusen i Venables, 2000).

Osim toga, međunarodna trgovina značajno se oslanja na trgovinske kredite. Integracija hrvatskog tržišta kredita (s tržištima kredita zemalja eurozone) omogućava Hrvatskoj lakši i jeftiniji pristup trgovinskim kreditima i na taj način potiče trgovinsku razmjenu sa zemljama

eurozone. Dakle, veći stupanj financijske integracije smanjuje troškove trgovinskih kredita i time potiče trgovinsku integraciju.

Pozitivan utjecaj financijske integracije na trgovinsku integraciju u svojima radovima potvrđuju Garcia-Herrero i Ruiz (2008), Aizenman i Noy (2009) te Antonakakis i Tondl (2014).

H32: Trgovinska integracija potiče usklađivanje poslovnog ciklusa Hrvatske s poslovnim ciklusima zemljama eurozone.

Trgovinska integracija usklađuje poslovne cikluse generiranjem učinaka na strani potražnje (multiplikator vanjske trgovine). Naime, pozitivni (negativni) šokovi outputa u jednoj zemlji povećavaju (smanjuju) potražnju za stranim dobrima u drugoj zemlji, tj. utječu na izvoz druge zemlje koji je važni čimbenik njezina rasta. Utjecaj navedenih šokova na poslovne cikluse ovisi o jačini trgovinskih poveznica između zemalja.

S obzirom na to da Hrvatska najveći dio vanjske trgovine ostvaruje sa zemljama eurozone, trgovinska integracija omogućava snažnije i brže prenošenje (pozitivnih i negativnih) šokova iz zemalja eurozone i potiče usklađivanje poslovnog ciklusa Hrvatske s poslovnim ciklusima zemalja eurozone.

Pozitivan utjecaj trgovinske integracije na usklađivanje poslovnih ciklusa u svojim istraživanjima potvrđuju Frankel i Rose (1998), Baxter i Kouparitsas (2005), Calderon, Chong i Stein (2007), De Haan, Inklaar i Jong-A-Pin (2008), Cerqueira i Martins (2009), Gouveia i Correia (2013) te Duran i Ferreira Lopes (2017).

Na slici 1. nalazi se shematski prikaz postavljenih glavnih istraživačkih hipoteza.

Slika 1. Shematski prikaz istraživačkih hipoteza

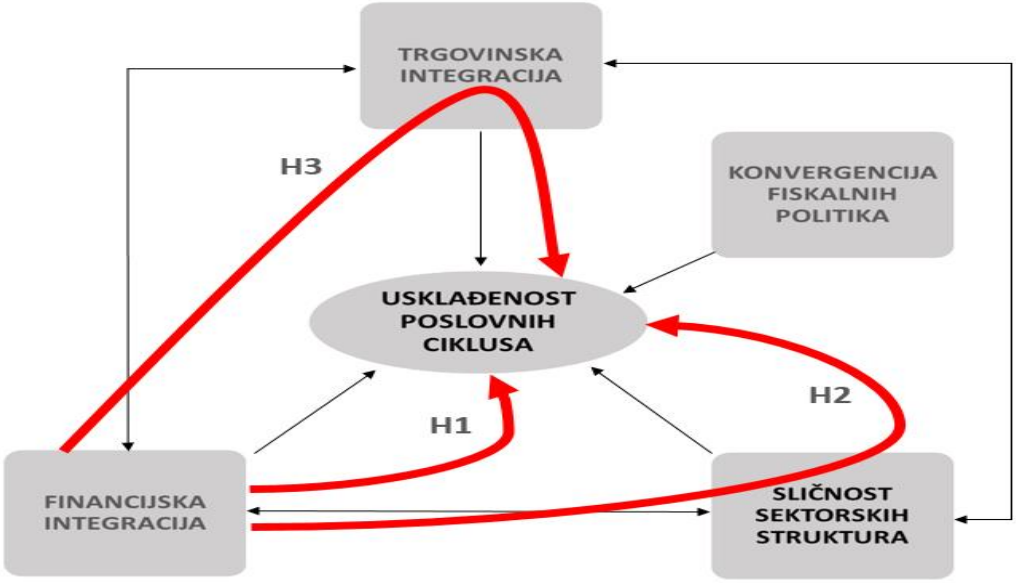

Izvor: Izrada autora

1.4. Metodologija znanstvenog istraživanja

Sukladno problemu i predmetu istraživanja oblikovana je specifična metodologija. U teorijskom dijelu disertacije, koji se temelji na prikupljanju i kritičkoj analizi relevantne znanstvene i stručne literature, korištene su opće znanstveno-istraživačke metode. Empirijski dio disertacije temelji se na dokazivanju postavljenih istraživačkih hipoteza. Na uzorku kojeg sačinjava Hrvatska i 19 zemalja eurozone (Austrija, Belgija, Cipar, Estonija, Finska, Francuska, Grčka, Irska, Italija, Latvija, Litva, Luksemburg, Nizozemska, Njemačka, Malta, Portugal, Slovačka, Slovenija i Španjolska) i obuhvaća vremensko razdoblje od 2001. do 2016. godine, analizirani su izravni i neizravni kanali utjecaja financijske integracije na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone koristeći sustav strukturnih jednadžbi, pri čemu je primijenjena metodologija koja se sastoji od nekoliko koraka.

Za procjenu poslovnih ciklusa korišten je jaz outputa izračunat prema metodi proizvodne funkcije. Na taj način uklonjena su ograničenja vezana uz korištenje univarijatnih filtara. Uzimajući u obzir nedostatke mjerenja usklađenosti poslovnih ciklusa u dosadašnjim

istraživanjima, u ovom istraživanju usklađenost poslovnih ciklusa mjerena je Cerquerira-Martinsovim (2009) indeksom koji je prikladan za korištenje u panel modelima. Osim toga, uklanja nedostatke Pearsonovog koeficijenta korelacije jer sagledava amplitudnu usklađenost koja je bitna za provođenje zajedničke monetarne politike, tj. usko je vezana za analizu uvođenja eura za Hrvatsku. S obzirom na nedostatke prethodnih istraživanja i ograničenja dostupnosti podataka, financijska integracija mjerena je količinski orijentiranom mjerom - izravnim stranim investicijama, koje su dostupne na bilateralnoj razini. Osim toga, financijska integracija mjerena je i cjenovno orijentiranom mjerom – razlikom povrata na desetogodišnje državne obveznice. Na taj način identificirati su različiti kanali utjecaja za koje teorija ističe da djeluju putem integriranih tržišta kapitala i kredita.

U skladu s teorijskim okvirom, osim financijske integracije u empirijskom modelu za regresorske varijable korišteni su istaknuti kriteriji iz teorije optimalnih valutnih područja – trgovinska integracija, sličnost sektorskih struktura i konvergencija fiskalnih politika. Trgovinska integracija mjerena je bilateralnim robnim tokovima; sličnost sektorskih struktura sumom apsolutnih razlika bruto dodanih vrijednosti pojedinih sektora između zemalja; a konvergencija fiskalnih politika apsolutnom razlikom strukturnih deficita zemalja. Za razliku od većine dosadašnjih istraživanja koja koriste presječne (engl. cross-section) podatke, kod procjene parametara modela u ovom istraživanju korišteni su panel podaci koji ne isključuju vremensku komponentu, tj. omogućavaju sagledavanje dinamike promjene.

Empirijski model sastojao se od sustava strukturnih jednadžbi (tri jednadžbe). Prvom jednadžbom analizirani su izravni kanali utjecaja financijske integracije na usklađivanje poslovnih ciklusa zemalja. Na taj način dokazivala se glavna istraživačka hipoteza H1. Drugom jednadžbom analiziran je neizravni utjecaj financijske integracije putem specijalizacije, čime se ujedno dokazivala istraživačka hipoteza H2. Istraživačka hipoteza H3 dokazivala se trećom jednadžbom kojom je analiziran neizravni utjecaj financijske integracije putem trgovinske integracije.

Konkretnije, u prvoj jednadžbi analiziran je izravni utjecaj financijske integracije na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone putem kreditnog i kapitalnog kanala. Također, analiziran je utjecaj i ostalih odrednica usklađivanja poslovnih ciklusa - trgovinske integracije, sličnosti sektorskih struktura i konvergencije fiskalnih politika. Za procjenu parametara u prvoj jednadžbi korišten je statički panel s fiksnim učinkom jer kontrolira učinke *time invariant*

varijabli za koje teorija ističe da imaju značajan utjecaj na usklađivanje poslovnih ciklusa, a nisu uključeni u empirijskom modelu utjecaja. Prije toga su napravljeni ekonometrijski testovi (Studentov t-test, Wooldridgeov test autokorelacije, modificirani Waldov test, Hausmanov test) s ciljem identifikacije osnovnih ekonometrijskih problema koji se mogu pojaviti prilikom panel analize.

Utjecaj financijske integracije na sličnost sektorskih struktura (čime se identificira neizravni utjecaj financijske integracije na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone putem kanala specijalizacije) analiziran je u drugoj jednadžbi. U skladu s rezultatima Studentovog t testa uzorak je podijeljen na dva dijela - pretkrizno i krizno te postkrizno razdoblje. S obzirom na autokorelaciju i heteroskedastičnost reziduala (potvrđenu Wooldridgeovim testom autokorelacije i modificiranim Waldovim testom) te suženu vremensku komponentu, za procjenu parametara modela korišten je PCSE (engl. panel-corrected standard error) procjenitelj.

Konačno, u trećoj jednadžbi, kojom je analiziran utjecaj financijske integracije na trgovinsku integraciju (čime se identificira neizravni utjecaj financijske integracije na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone putem kanala trgovinske integracije), korišten je statički panel s fiksnim učinkom (u skladu s rezultatima Hausmanovog testa).

Prilikom obrade podataka i izračuna varijabli korišten je Microsoft Excel 16; kod izrade grafikona (kretanje varijabli u vremenu, dijagrami rasipanja) i izračuna deskriptivne statistike (minimumi i maksimumi varijabli, prosječne vrijednosti varijabli, standardne devijacije, normalnost distribucije, stacionarnost varijabli, i sl.) korišten je EViews 9; a kod provođenja osnovnih ekonometrijskih testova (Studentov t-test, Hausmanov test, Wooldridge test autokorelacije, modificirani Waldov test) i procjene parametara panel modela (statički panel s fiksnim učinkom, PCSE procjenitelj) korištena je Stata 14.2.

1.5. Struktura rada

Doktorska disertacija organizirana je u šest poglavlja. U UVODU je prikazan problem i predmet istraživanja te definirani ciljevi istraživanja. Osim toga definirane su i objašnjene tri glavne istraživačke hipoteze s pomoćnim hipotezama. Dodatno, prikazana je metodologija znanstvenog istraživanja i ukratko objašnjena struktura rada.

U drugom poglavlju USKLAĐENOST POSLOVNIH CIKLUSA KAO META KRITERIJ TEORIJE OPTIMALNIH VALUTNIH PODRUČJA dan je kronološki pregled razvoja teorije optimalnih valutnih područja od njezinih početaka 1960-ih godina te je kritički analizirana teorija optimalnih valutnih područja. Dodatno, prikazani su važni teorijski doprinosi teoriji kroz Krugmanovu hipotezu o specijalizaciji i Frankel-Roseovu hipotezu o endogenosti. Također, definirani su poslovni ciklusi, prikazane metode procjene poslovnih ciklusa i mjere usklađenosti poslovnih ciklusa te objašnjene prednosti i nedostaci različitih metoda procjene i mjera usklađenosti poslovnih ciklusa. Konačno, dan je pregled dosadašnjih istraživanja usklađenosti poslovnih ciklusa koja u svojoj analizi uključuju Hrvatsku.

Treće poglavlje ZNAČAJ FINANCIJSKE INTEGRACIJE ZA MONETARNO INTEGRIRANJE sastoji se od četiri potpoglavlja u kojima je definirana financijska integracija, objašnjene prednosti i nedostaci financijske integracije, objašnjena važnost financijske integracije u procesu monetarnog integriranja te prikazani načini mjerenja financijske integracije u sličnim istraživanjima.

U četvrtom poglavlju UTJECAJ FINANCIJSKE INTEGRACIJE NA USKLAĐIVANJE POSLOVNIH CIKLUSA sistematizirani su i objašnjeni transmisijski kanali utjecaja (izravni – putem kanala bilance i blagostanja; te neizravni putem trgovinske integracije i sektorske specijalizacije) te je dan kronološki pregled dosadašnjih istraživanja utjecaja financijske integracije na usklađivanje poslovnih ciklusa koji u svojoj analizi uključuju Hrvatsku.

Peto poglavlje EMPIRIJSKA ANALIZA UTJECAJA FINANCIJSKE INTEGRACIJE NA USKLAĐIVANJE POSLOVNOG CIKLUSA HRVATSKE SA ZEMLJAMA EUROZONE sastoji se od pet potpoglavlja. U njemu su prikazane i objašnjene istraživačke hipoteze, dan je empirijski model istraživanja, objašnjene su i izračunate varijable i indikatori te je prostorno i vremenski definiran uzorak na kojem će se vršiti istraživanje. Osim toga, napravljena je

deskriptivna statistika, korelacijska matrica, dijagrami rasipanja i provedena ekonometrijska panel analiza. Konačno, dan je kritički osvrt na rezultate istraživanja i napravljena usporedba dobivenih rezultatima s rezultatima dosadašnjih sličnih istraživanja.

U šestom poglavlju ZAKLJUČNA RAZMATRANJA prikazana je rasprava o rezultatima istraživanja, doprinosi i implikacije rezultata istraživanja. Konačno, istaknuta su ograničenja ovog istraživanja te dane smjernice za buduća istraživanja.

2. USKLAĐENOST POSLOVNIH CIKLUSA KAO META KRITERIJ TEORIJE OPTIMALNIH VALUTNIH PODRUČJA

U ovom poglavlju prikazan je razvoj teorije optimalnih valutnih područja kao konceptualnog okvira za procjenu koristi i troškova monetarnog integriranja. S obzirom da se procjena troškova najbolje očituje kroz stupanj usklađenosti poslovnih ciklusa, navedeni kriterij se smatra meta kriterijem teorije optimalnih valutnih područja, tj. sveobuhvatnim kriterijem (engl. catch-all) monetarnog integriranja. Analizom razvoja teorije identificirani su kriteriji, kao i njihovi međusobni odnosi. Poseban naglasak stavljen je na financijsku integraciju čijim uključivanjem dolazi do fundamentalnih promjena u postavkama Mundellovog modela optimalnog valutnog područja. S obzirom na problem statičnosti tradicionalne teorije optimalnih valutnih područja, u drugom potpoglavlju analizirani su teorijski doprinosi (teorija o endogenosti; teorija o specijalizaciji) koji su važni zbog uvođenja dinamičke komponente, tj. analize međuodnosa između kriterija u svrhu kvalitetnije procjene troškova prihvaćanja zajedničke valute. Cilj poglavlja je identificirati konceptualni, kvalitativni suodnos kriterija prema meta kriteriju u svrhu identifikacije varijabli modela utjecaja.

2.1. Pojam i razvoj teorije optimalnih valutnih područja

Teorija optimalnih valutnih područja počinje se razvijati šezdesetih godina prošlog stoljeća. U tom razdoblju već je završena početna faza procesa europske integracije (Europska zajednica za ugljen i čelik osnovana je 1952. godine; Europska zajednica za atomsku energiju (Euratom) i Europska ekonomska zajednica (EEZ) osnovane su 1958. godine), a karakterizira ga Bretton-Woodski sustav fiksiranih deviznih tečajeva te kontrola kretanja kapitala u mnogim državama.

Mongelli (2002) definira optimalno valutno područje kao optimalnu geografsku domenu jedinstvene valute ili nekoliko valuta čiji je tečaj neopozivo fiksiran (engl. irrevocably pegged). Domena optimalnog valutnog područja zadana je granicama suverenih država koje odluče prihvatiti jedinstvenu valutu ili fiksirati tečaj, a optimalnost se definira u okviru kriterija koje je potrebno zadovoljiti.

Tradicionalna teorija optimalnih valutnih područja ističe (poželjne) kriterije za monetarno integriranje:

- fleksibilnost cijena i plaća (Friedman, 1953);
- mobilnost faktora proizvodnje (Mundell, 1961);
- financijska integracija (Ingram, 1962);
- stupanj ekonomske otvorenosti (McKinnon, 1963);
- diversifikacija u proizvodnji i potrošnji (Kenen, 1969);
- fiskalna integracija (Kenen, 1969);
- politička integracija (Mintz,1970),
- sličnost inflacijskih stopa (Fleming, 1971);
- nacionalna sklonost prema inflaciji (Magnifico, 1971);
- promjene realnog deviznog tečaja (Vaubel, 1976).

Mongelli (2008) ističe da zadovoljavanje navedenih kriterija smanjuje korisnost nominalnog deviznog tečaja kao sredstva prilagodbe; potiče unutarnju i vanjsku ravnotežu; smanjuje utjecaj pojedinih vrsta šokova; i olakšava prilagodbu na nastale šokove.

Teorija optimalnih valutnih područja razvila se iz rasprave o koristima i troškovima korištenja sustava fiksnog deviznog tečaja u odnosu na sustav fluktuirajućih deviznih tečajeva. Zbog toga zanemaruje postojanje čitave skupine upravljano-fluktuirajućih deviznih tečajeva, već se orijentira isključivo na izbor između dvije krajnosti – slobodno fluktuirajući i fiksni devizni tečaj. Temeljno pitanje na koje teorija optimalnih valutnih područja pokušava dati odgovor je pod kojim uvjetima je poželjno formirati valutno područje (prihvaćanjem zajedničke valute ili fiksiranjem deviznog tečaja između valuta unutar područja). Najjednostavnije rečeno, zemlje bi formirale valutno područje u očekivanju da koristi od takvog poteza nadilaze troškove.

Glavni zagovornik fluktuirajućeg deviznog tečaja 50-ih godina 20. stoljeća bio je Milton Friedman koji je smatrao da fluktuirajući devizni tečaj bolje apsorbira egzogene šokove od fiksnog deviznog tečaja. U situaciji relativno rigidnih cijena i plaća te niske mobilnosti faktora proizvodnje, jedini način da se, zbog pojave pozitivnih (negativnih) šokova u ponudi ili potražnji, izbjegne veća inflacija (nezaposlenost) je aprecijacija (deprecijacija) tečaja (Friedman, 1953).

Promjenom tečaja ekonomija se vraća u početno stanje interne i eksterne ravnoteže. U uvjetima fiksnog deviznog tečaja to nije moguće pa će navedeni šokovi utjecati na zaposlenost (inflaciju). Friedman (1953) ističe važnost fleksibilnosti cijena i plaća za zemlje koje koriste zajedničku valutu. Naime, što su cijene i plaće fleksibilnije, slabiji je utjecaj šokova na zaposlenost i/ili inflaciju u zemljama. To u konačnici smanjuje potrebu za promjenom nominalnog deviznog tečaja. Međutim, ako su cijene i plaće rigidne prema dolje, onda je nominalni tečaj vrlo bitan instrument neutraliziranja šokova i gubitak direktnog utjecaja na njega predstavlja trošak za zemlje koje prihvate zajedničku valutu (fiksiranje tečaja). U tom slučaju fleksibilni devizni režim bio bi povoljnije rješenje.

Friedmanovu tezu replicira Robert Mundell (1961) u članku koji predstavlja početak razvoja teorije optimalnih valutnih područja. U njemu Mundell prikazuje model zemlje koja se sastoji od dvije regije: regije A i regije B. Ako u regiji A agregatna potražnja naraste, a u regiji B opadne, fluktuirajući devizni tečaj neće vratiti zemlju u stanje ravnoteže. Zemlja će se moći riješiti nezaposlenosti ili inflacije, ali nikako oba problema. U slučaju pomaka potražnje regije B prema proizvodima regije A, doći će do rasta nezaposlenosti u regiji B i rasta inflacije u regiji A. U takvoj situaciji kao ključni mehanizam (koji može vratiti zemlju u stanje ravnoteže) Mundell (1961) ističe mobilnost rada. Ako postoji visoka mobilnost rada između regija, rad će se premjestiti iz regije B u regiju A i automatski uspostaviti ravnotežu po pitanju inflacije i nezaposlenosti u regijama. Dakle, ako između zemalja postoji visoka mobilnost rada (i fleksibilnost cijena i nadnica) zemlje bi trebale imati fiksni devizni tečaj između sebe i fluktuirajući devizni tečaj prema ostatku svijeta.

U skladu s navedenim Mundell (1961) definira optimalno valutno područje: regija unutar koje postoji faktorska mobilnost (unutarnja faktorska mobilnost), a izvan koje su faktori nemobilni (vanjska faktorska imobilnost). Regije s visokom faktorskom mobilnošću nisu nužno definirane nacionalnim granicama. Optimalno valutno područje može obuhvaćati nekoliko zemalja, a isto tako može postojati više optimalnih valutnih područja unutar jedne zemlje. Mundell (1961) ističe da na veličinu optimalnog valutnog područja utječu tri dodatna čimbenika: 1) s gledišta funkcije novca kao sredstva razmjene optimalno valutno područje je cijela svjetska ekonomija (s jednom valutom nema transakcijskih troškova); 2) valutno područje mora biti dovoljno veliko da spriječi

utjecaj bilo kojeg pojedinca na tržišnu cijenu valute (onemogući špekulacijske napade); 3) valutno područje mora biti dovoljno veliko da ograniči problem novčane iluzije[11].

Kenen (1969) upozorava na problem shvaćanja pojma Mundellove regije. Mundellova regija je homogeni skup proizvođača koji koriste istu tehnologiju, dijele iste ekonomske uvjete i suočavaju se s istom funkcijom potražnje. Kao takva nije nikakva politička cjelina, već umjetno stvorena regija, a mnoge pogrešne pretpostavke o vođenju monetarne politike u malim i otvorenim zemljama proizlaze upravo iz pogrešnog shvaćanja pojma Mundellove regije (Kenen, 1969).

Mckinnon (1963) razlikuje geografsku mobilnost rada (koju podrazumijeva Mundell) i industrijsku mobilnost rada (mobilnost rada između različitih industrija). Ističe česti slučaj imobilnosti radne snage između regija u kojem je teško razlikovati geografsku i interindustrijsku nemobilnost. Kenen (1969) ističe da savršena međuregionalna mobilnost radne snage zahtijeva savršenu profesionalnu mobilnost koja se može postići jedino u slučaju homogenosti rada, tj. vrlo sličnim zahtjevima za vještinama. Navedeno implicira da regija mora biti vrlo mala, tj. ograničava se na područje proizvodnje jednog proizvoda (Kenen, 1969). Toga je bio svjestan i Mundell (1961) koji ističe da takav aranžman graniči zdravom razumu.

Mobilnost rada smanjuje potrebu za promjenom realnih cijena faktora proizvodnje i nominalnog deviznog tečaja uslijed pojave šokova. Također, mobilnost rada može pridonijeti uravnoteženju u slučaju rigidnih cijena i plaća. S druge strane, transfer radne snage povezan je s prijenosom potrošnje radnika iz jedne zemlje u drugu što može smanjiti stabilizirajući učinak mobilnosti radne snage. Osim toga, mobilnost rada povezana je s brojnim ekonomskim (troškovi preseljenja, oporezivanje, rizik nezapošljavanja) i neekonomskim (kulturološke razlike, jezične prepreke, obiteljska perspektiva, i sl.) troškovima što implicira da je uloga mobilnosti rada kao mehanizma prilagodbe u kratkom roku slaba, a njezina primjenjivost ograničena. Ipak, u srednjem i dugom roku može biti snažan mehanizam prilagodbe koji pridonosi sveukupnom blagostanju.

Međunarodna mobilnost rada usko je povezana i može se nadomjestiti fleksibilnošću tržišta rada (Kundera, 2012). Fleksibilnost tržišta rada uglavnom označava elastičnost plaća te međuregionalnu i međusektorsku mobilnost rada, pri čemu fleksibilnost plaća predstavlja najbolji

[11] Pojedinac nije voljan prihvatiti promjenu realnog dohotka putem prilagodbe plaće, ali je istodobno voljan prihvatiti promjenu realnog dohotka kroz promjenu deviznog tečaja. Novčana iluzija je opadajuća funkcija veličine valutnog područja.

instrument prilagodbe jer može zamijeniti mobilnost rada u funkciji uspostavljanja vanjske ravnoteže. Ako između partnerskih zemalja (u valutnom području) postoji fleksibilnost tržišta rada, zemlje neće imati velike troškove prilagodbe u slučaju pomaka međunarodne potražnje. Ako ne postoji fleksibilnost tržišta rada, partnerske zemlje mogu imati velike strukturne probleme zbog pojave asimetričnih šokova. Kundera (2012) ističe da je u tom slučaju potrebno da zemlje imaju određeni stupanj fleksibilnosti deviznog tečaja.

Promoviranje geografske mobilnosti na razini EU jedan od glavnih ciljeva Europske komisije. Pravo na život i rad u drugim zemljama članicama EU simbol je Europske integracije i identiteta. Osim toga, mobilnost rada omogućava bolje sučeljavanje ponude i potražnje za radom u svrhu povećanja učinkovitosti rada. Dodatno, veća mobilnost rada (uz fleksibilnost tržišta rada i mogućnost zapošljavanja) nužna je kao odgovor na snažnu globalnu konkurentnost, rapidnu tehnološku promjenu i zahtjeve društva znanja.

Mobilnost rada u Europi manja je nego u Sjedinjenim Američkim Državama (SAD), a glavna ograničenja europskoj mobilnosti rada u odnosu na SAD su jezične i kulturološke prepreke u Europi (Arpaia i ostali 2016) . Dodatno, manjak mobilnosti rada pripisuje se kombinaciji institucionalnih i administrativnih čimbenika koji uključuju: ograničenu prekograničnu prenosivost socijalne zaštite i prava na mirovinu, administrativne poteškoće i visoke troškove stjecanja statusa rezidenta, nedostatak usporedivosti i uzajamnog priznavanja profesionalnih kvalifikacija te ograničenja zapošljavanja u javnom sektoru. Arpaia i ostali (2016) navode da manje od 5% radno sposobnih građana EU-a žive u državi različitoj od države rođenja, za razliku od SAD-a u kojoj oko 30% radno sposobne populacije živi u državi različitoj od države rođenja.

McKinnon (1963) definira optimalno valutno područje kao područje jedinstvene valute u kojem je (putem instrumenata monetarne i fiskalne politike te fleksibilnog deviznog tečaja prema zemljama izvan valutnog područja) moguće održati tri (često suprotstavljena) cilja: punu zaposlenost, učinkovitu alokaciju resursa i vanjsku ravnotežu. Ključnim kriterijem optimalnog valutnog područja smatra stupanj otvorenosti ekonomije, a definira ga kao odnos razmjenjivih (engl. tradeable) i nerazmjenjivih (engl. non-tradeable) dobara.

Navodi primjer male ekonomije u kojoj je udio izvoznih i uvoznih dobara u odnosu na nerazmjenjiva dobra visok. U sustavu fleksibilnih deviznih tečajeva cijene izvoznih i uvoznih dobara (izražene u domaćoj valuti) variraju zajedno s deviznim tečajem, dok se cijena

nerazmjenjivih dobara smatra konstantnom. Zbog toga se fluktuacije deviznog tečaja u maloj otvorenoj ekonomiji suprotstavljaju naporima za održavanjem stabilnosti cijena. Situacija je drugačija u velikoj ekonomiji s većim udjelom proizvodnje nerazmjenjivih dobara. U takvoj ekonomiji devalvacija bi imala učinak na cijene uvoznih i izvoznih dobara, ali učinak na opći nivo cijena bio bi manji nego u slučaju male otvorene ekonomije. Kod pomaka od zatvorenijih prema otvorenijim ekonomijama, fleksibilni devizni tečaj postaje manje učinkovit mehanizam za uspostavljanje vanjske ravnoteže te nanosi više štete unutrašnjoj stabilnosti cijena (McKinnon, 1963).

Otvorenost ekonomije može se definirati na više načina: stupanj trgovinske integracije između zemalja (udio bilateralnog uvoza i izvoza u BDP-u); omjer razmjenjivih i nerazmjenjivih dobara i usluga u proizvodnji i potrošnji; granična sklonost uvozu; međunarodna mobilnost kapitala; i sl. Iako se navedene definicije preklapaju nisu sinonimi. Tako na primjer, zemlja može imati visoki udio razmjenjivih dobara, ali nisku razinu uvoza i izvoza. Što je viši stupanj otvorenosti ekonomije, to će promjene u međunarodnim cijenama (izravno i neizravno) jače utjecati na razinu domaćih cijena. Deprecijacija će se brže prenijeti na cijene međunarodno razmjenjivih dobara i trošak življenja te će nominalni devizni tečaj biti manje koristan instrument prilagodbe (Mongelli, 2008).

Imajući u vidu da savršena mobilnost rada ne postoji, Kennen (1969) za ključni kriterij optimalnog valutnog područja ističe stupanj diversifikacije proizvoda. Diversificirano gospodarstvo ima razgranati izvozni sektor. Svaka od industrija u gospodarstvu može biti predmetom šoka, ali ako su šokovi nekorelirani, onda se negativan šok u jednoj industriji poništava pozitivnim šokom u drugoj industriji. U tom slučaju ukupni učinak je neutralan, a izvoz stabilan. Naravno, ako je zemlja pogođena zajedničkim šokom, onda će cijeli izvozni sektor biti pogođen i diversifikacija u tom slučaju neće pomoći.

U slučaju da zemlja nema diversificiranu proizvodnju (npr. proizvodi samo jedan proizvod koji ujedno i izvozi), pad izvoznih prihoda (zbog pojave negativnog šoka u potražnji) može se smanjiti upotrebom fluktuirajućeg deviznog tečaja. Pad potražnje za izvoznim proizvodima smanjuje potražnju za domaćom valutom (uzrokuje pad vrijednosti valute). Deprecijacija deviznog tečaja ponovo će povećati izvozne prihode jer izvoznik za svaku jedinicu strane valute dobiva više jedinica domaće valute.

Ako zemlja ima fiksni devizni tečaj mehanizam deprecijacije ne može se koristiti i prilagodba će se izvršiti kroz povećanje nezaposlenosti i/ili smanjenje cijena/plaća. Kennen (1969) zaključuje da:

- proizvodno diversificirano nacionalno gospodarstvo ne mora prolaziti promjene u uvjetima trgovanja tako često i u velikim razmjerima kao specijalizirana gospodarstva;
- pad potražnje za glavnim izvoznim proizvodom manje utječe na nezaposlenost u diversificiranom nego u specijaliziranom izvoznom gospodarstvu – diversifikacija proizvodnje ne smanjuje samo vjerojatnost pojave šokova, već ublažava štetni utjecaj šokova na zaposlenost i ukupnu proizvodnju;
- u diversificiranom gospodarstvu slabija je poveznica između inozemne i domaće potražnje te između dinamike izvoza i nivoa investicija. Dakle, ako je zemlja dovoljno diversificirana može prihvatiti manje troškove napuštanja vlastite u zamjenu za koristi koje proizlaze iz korištenja zajedničke valute.

Kod pojave sektorski specifičnih šokova visoki stupanj diversifikacije smanjuje potrebu za promjenom uvjeta trgovine putem nominalnog deviznog tečaja jer takvi šokovi pogađaju samo određeni sektor. Visoko diversificirane zemlje rjeđe se suočavaju s velikim promjenama u potražnji za svojim proizvodima - potražnja za pojedinim proizvodima raste, a za pojedinim opada pa će povećanje izvoza pojedinih proizvoda nadoknaditi manji izvoz drugih proizvoda. Zemlja koja proizvodi veći broj proizvoda suočit će se s manjim padom u ukupnoj proizvodnji ako potražnja za njezinim proizvodima na vanjskom tržištu padne, a neutralizirajući mehanizam je jači što su proizvodi diversificiraniji. Kenen (1969) zaključuje da bi zemlja s manjim stupnjem diversifikacije (najčešće manje zemlje) trebala upotrebljavati fleksibilni devizni tečaj za ublažavanje vanjskih šokova, dok bi za visoko diversificirane ekonomije bilo korisnije formirati valutno područje.

Osim diversifikacije, Kenen (1969) ističe fiskalnu integraciju koja putem fiskalnih transfera može ukloniti probleme nastale djelovanjem asimetričnih šokova između zemalja unutar valutnog područja. Kada su pogođene negativnim šokovima, zemlje koje su uključene u supranacionalni sustav ostvaruju mogućnost redistribucije sredstava iz centraliziranog proračuna. Na taj način smanjuje se utjecaj šokova i potreba za prilagodbom nominalnog deviznog tečaja. Naime, zemlja pogođena negativnim šokovima primit će štednju od zemalja pogođenih pozitivnim šokovima

kroz fiskalni sustav (i sustav socijalne zaštite) putem javnih transfera. Ovaj oblik transfera je dobrovoljne prirode jer se usmjerava putem poreza i doprinosa za socijalno osiguranje. Stoga pogodnosti socijalne zaštite ostvarene u zemljama s poteškoćama neće biti popraćene zahtjevom za isplatu kamata (zbog prijenosa štednje) od strane zemalja u ekspanziji. Sustav fiskalnih transfera naravno zahtijeva i određeni stupanj političke integracije, odnosno želju zemalja za poduzimanjem takvih akcija.

Međutim, stavovi oko korištenja fiskalnih transfera u valutnom području nisu usuglašeni. Naime, dio ekonomista smatra da je korištenje institucionalnog mehanizma za redistribuciju dohotka između regija/zemalja esencijalno za funkcioniranje valutnog područja, dok se drugi dio ne slaže po pitanju korištenja netržišnih mehanizama prilagodbe u valutnom području. Protivnici fiskalnih transfera ističu da dugoročni transferi dohotka samo odgađaju nužne strukturne reforme. Također, postoji opasnost od pojave moralnog hazarda – zemlje/regije će akumulirati velike dugove u očekivanju de će ti dugovi u konačnici biti pokriveni fiskalnim transferima iz središnjeg budžeta.

Iskustvo s regionalnim budžetskim transferima unutar zemalja (npr. Italija, Belgija, Njemačka) pokazuju da je vrlo teško ovakve transfere koristiti privremeno. Transferi putem središnjeg sustava vrlo često imaju tendenciju stjecanja trajnog karaktera u slučaju kad regija iskusi negativan šok (De Grauwe, 2018). Veliki i trajni transferi mogu stvoriti političke probleme zbog negodovanja stanovnika prosperitetnih regija da plaćaju za takve transfere. Ako je osjećaj nacionalnog identiteta slab može doći i do raspada zemlje.

Korisnost fiskalnih transfera ovisi i o prirodi šokova. Ako šokovi prvenstveno utječu na potražnju, onda fiskalni transferi imaju smisla. S druge strane, ako se radi o šokovima ponude, u tom slučaju poticanje potražnje može samo pogoršati situaciju.
Dalje, iako kratkoročni ciklički šokovi zahtijevaju izravni transfer sredstava u svrhu stabilizacije, postoji opasnost da se stabilizacija u konačnici pretvori u redistribuciju. Slično tome, transferi u svrhu strukturnih reformi su neodgovarajući instrumenti za kratkoročnu stabilizaciju. Transferi u svrhu stabilizacije najučinkovitiji su putem mehanizama koji djeluju brzo i automatski poput privatnih kapitalnih tokova.

Valutna područja s velikim središnjim budžetom mogu koristiti automatske transfere u svrhu stabilizacije. Ono što institucionalnu arhitekturu eurozone čini iznimnom i razlikuje je od ostalih valutnih područja (npr. SAD) je nepostojanje središnjeg fiskalnog budžeta koji bi omogućio

fiskalne transfere u svrhu stabilizacije. Upravo se nedostatak središnjeg budžeta (koji se može koristiti za podjelu rizika) ističe kao veliki problem zbog kojeg se u budućnosti mogu pojaviti značajni troškovi (u slučaju pojave asimetričnih šokova). Dakle, fiskalna politika eurozone još uvijek je decentralizirana što pokazuje da je nivo fiskalne integracije zemalja eurozone vrlo nizak.

Grgić, Bilas i Šimović (2006) ističu da se struktura fiskalnog sustava EU može sagledati preko tri segmenta:

- proračun EU - predstavlja jedini instrument provođenja fiskalne politike sa središnje, supranacionalne razine EU. Proračun EU je specifičan, i u odnosu na klasične nacionalne proračune postoje određene razlike: 1) Prihodna i rashodna strana proračuna EU razlikuju se od nacionalnih proračuna; 2) Proračun EU je relativno malen u odnosu na veličinu gospodarstava koja pokriva (prihodi proračuna EU čine oko 1% BDP-a EU, dok se veličina prihoda nacionalnih proračuna kreće od 15% do 50% za pojedinu državu); 3) Strože i čvršće je reguliran i strogo je uravnotežen; 4) Onemogućeno je zaduživanje i posuđivanje sredstava korisnicima proračuna.
- usklađivanje (harmonizacija) poreznih sustava - nametanje poreza u isključivoj je nadležnosti vlada zemalja članica EU, a porezni propisi pripadaju nacionalnom poreznom sustavu određene zemlje članice. Ipak, budući da je članstvo u EU utemeljeno na međunarodnom ugovoru koji za članice sadrži razna prava i obveze, porezni suverenitet je ograničen, odnosno podijeljen između EU i zemalja članica. U cilju jačanja zajedničkog unutrašnjeg tržišta, EU je raznim smjernicama i drugim pravnim propisima utjecala na formiranje poreznih sustava zemalja članica EU i na taj način fiskalnu harmonizaciju iskoristila kao alternativni pristup fiskalnom federalizmu (Grgić, Bilas i Šimović, 2006).
- koordinacija proračunskih politika zemalja članica - putem fiskalnih pravila EU koja se prvenstveno odnose na Maastrichtske kriterije konvergencije i Pakt o stabilnosti i rastu.

Maastrichtski kriteriji konvergencije podrazumijevaju: 1) Postizanje visokog stupnja stabilnosti cijena, mjerenog stopom inflacije, koja ne smije biti veća od 1,5 postotnih poena prosječne stope inflacije triju država članica EU s najnižom inflacijom; 2) Održivost javnih financija, definiranih umjerenim proračunskim deficitom, koja obuhvaća dva kriterija: a) Udio proračunskog deficita opće države u bruto domaćem proizvodu ne smije prelaziti 3%; b) Udio bruto duga opće države u

bruto domaćem proizvodu ne smije prelaziti 60%; 3) Održavanje normalnih fluktuacija tečaja u granicama određenim Tečajnim mehanizmom Europskog monetarnog sustava najmanje dvije godine; 4) Dugoročnu kamatnu stopu na državne obveznice koja ne smije za više od dva postotna poena prijeći prosjek tri zemlje članice EU s najnižom inflacijom.
Pakt o stabilnosti i rastu osigurava provođenje Maastrichtskih kriterija, a usvojen je rezolucijom Europskog vijeća i dvjema uredbama vijeća u kojima su detaljno razrađeni tehnički detalji dogovora u smislu nadzora proračunskih stavki i koordinacije ekonomskih politika pri pojavi prekomjernog deficita. Pakt o stabilnosti i rastu otvara mogućnost Vijeću da kazni svaku zemlju članicu koja ne poduzima odgovarajuće mjere da bi uklonila prekomjerni deficit (tzv. procedura prekomjernog deficita). Kaznene mjere u početku imaju oblik beskamatnog depozita koji se može pretvoriti u globu ako se deficit ne korigira u roku dvije godine. Ipak, ne postoje fiksna pravila koja reguliraju kaznene mjere, već one ovise o subjektivnoj prosudbi Vijeća o razlozima nastanaka prekomjernog deficita.

Financijska integracija jedan je od ključnih kriterija za monetarno integriranje i funkcioniranje valutnih područja. Ingram (1962) ističe da financijska integracija smanjuje potrebu za prilagodbom nominalnog deviznog tečaja. Naime, ako između zemalja postoje snažne financijske poveznice, zemlja pogođena negativnim šokom može se zadužiti i na taj način smanjiti jaz u financiranju. Dakle, tokovi kapitala između zemalja mogu pomoći u smanjenju privremenih neravnoteža.

Kod visokog stupnja financijske integracije male promjene kamatnih stopa potiču ravnotežno kretanje kapitala među zemljama što smanjuje razlike u kamatnim stopama, olakšava financiranje vanjskih neravnoteža i omogućava efikasnu alokaciju resursa (Mongelli, 2008).

Mobilnost kapitala ima kratkoročnu i dugoročnu ulogu. U kratkom roku kapitalni tokovi uravnotežuju bilance plaćanja zemalja (neovisno o tome imaju li zemlje vlastite valute ili pripadaju valutnom području). Također, kapitalni tokovi u kratkom roku olakšavaju prilagodbu na šokove. U dugom roku mobilnost kapitala nužna je zbog financiranja strukturnih promjena nužnih za optimalnost valutnog područja.
Međutim, financijska integracija nije zamjena za trajnu prilagodbu (kad je ona potrebna), već može samo ugladiti proces. Privremeni financijski tokovi mogu potaknuti odgodu stvarnog

prilagođavanja i otežati ga u kasnijoj fazi. Dodatno, financijska integracija može dovesti do destabilizirajućeg kretanja kapitala (Mongelli, 2008).

Kao što je već ranije navedeno, teorija optimalnih valutnih područja nastaje 60-ih godina dvadesetog stoljeća. Globalnu ekonomiju iz tog razdoblja karakterizira ograničenje kretanja kapitala. Upravo u takvom okruženju svoj razvoj počinje teorija optimalnih valutnih podučja, stoga je i razumljivo da tradicionalna teorija optimalnih valutnih područja nije stavljala preveliki naglasak na financijsku integraciju. Međutim, od Mundellovog članaka iz 1961. godine došlo je fundamentalnih promjena po pitanju kapitalnih tokova. Naime, Nixonova suspenzija konvertibilnosti dolara za zlato 1973. godine omogućila je snažnije kretanje kapitala, tj. financijsko integriranje zemalja.

Time faktorska nemobilnost, kao glavna prepreka formiranju optimalnog valutnog područja u Mundellovom (1961) modelu, više ne predstavlja problem. Naime, u slučaju nemobilnog rada postoji drugi ključni čimbenik koji ga može zamijeniti - mobilni kapital. Uzimajući u obzir financijsku integraciju, otvoren je prostor za potpuno novi, dinamičniji pogled na teoriju optimalnih valutnih područja koji ističe endogenu prirodu OCA kriterija. Upravo iz toga proizlazi važnost financijske integracije kao jednog od ključnih čimbenika monetarnog integriranja i funkcioniranja vautnog područja. Dodatno, na taj način omogućeno je i kvantitativno mjerenje koristi i troškova prihvaćanja zajedničke valute.

Dabrowski (2002) ističe da tradicionalna teorija optimalnih valutnih područja asimetrične šokove i ograničenja u faktorskoj mobilnosti smatra egzogenima, što je točno u kratkom i srednjem roku. Međutim, u dugom roku oni postaju endogeni. Očigledno je da monetarno integriranje potiče trgovinske i kapitalne tokove te usklađivanje fiskalnih politika unutar valutnog područja. Osim toga ohrabruje i mikroekonomske reforme koje dereguliraju tržište rada, kapitala i proizvoda. Svi ti čimbenici u konačnici smanjuju rizik od pojave asimetričnih šokova i povećavaju faktorsku mobilnost. Čak i sam Mundell (1973) u promijenjenim uvjetima uviđa važnost financijske integracije kao mehanizma podjele rizika te se zalaže za korištenje zajedničke valute[12] koje potiče endogeno djelovanje financijske integracije.

[12] Mundell (1973) implicitno pretpostavlja učinkovita međunarodna financijska tržišta u situaciji fiksnih tečajeva

Međutim, iako bi trebala omogućiti vraćanje sustava u ravnotežu, tj. zamijeniti devizni tečaj kao ultimativni apsorber šokova i instrument prilagodbe, pojava europske dužničke krize ukazala je na nedostatke financijske integracije i dovela u pitanje endogenu prirodu njezinog djelovanja.

Fleming (1971) ističe važnost sličnosti stopa inflacije kao jednog od ključnih kriterija optimalnog valutnog područja. Kad su inflacijske stope zemalja slične i stabilne, uvjeti trgovine ostat će stabilni, smanjit će se učestalost pojave vanjskih neravnoteža i potreba za prilagodbom nominalnog deviznog tečaja. Slično tome, Magnifico (1971) uvodi koncept nacionalne sklonosti inflaciji kao važan kriterij monetarnog integriranja. Naime, zemlje s različitim preferencijama prema inflaciji i nezaposlenosti imat će troškove prilikom formiranja valutnog područja jer će morati izabrati manje poželjne točke na Phillipsovoj krivulji. S druge strane nisu sve razlike u stopama inflacije između zemalja problematične. U nekim zemljama može se javiti Ballasa-Samuelsonov efekt[13] dok se proces rasta ne završi.

Sličnost stopa inflacije jedan je od temeljnih kriterija ugovora iz Maastrichta prema kojem stopa inflacije zemlje članice ne smije prelaziti inflaciju triju zemalja članica s najnižom inflacijom za više od 1,5 postotnih bodova. Dodatno, definirani su i fiskalni kriteriji zbog straha od inflacijskog pritiska koji proizlazi iz visokog deficita i javnog duga[14].

Mongelli (2008) ističe da je volja za političkim integriranjem jedan je od ključnih kriterija za stvaranje valutnog područja jer utječe na poštivanje zajedničkih obveza, podupire suradnju oko raznih ekonomskih politika i potiče institucionalno povezivanje.
Politička integracija smanjuje rizik od pojave asimetričnih šokova političkog podrijetla. Naime, politika potrošnje i oporezivanja nalazi se u rukama nacionalnih vlada. Stoga unilateralne odluke o promjeni politike (povećanje/smanjenje potrošnje i/ili oporezivanja) mogu stvoriti asimetrične šokove. Politika plaća i socijalnog osiguranja također se određuje na nacionalnoj razini što opet stvara mogućnost pojave asimetričnih šokova.. Uspješno valutno područje treba razuman stupanj usklađenosti inflacije, zaposlenosti i gospodarskog rasta između zemalja koje joj pripadaju što

[13] Ballasa-Samuelsonov efekt implicira da je optimalna inflacijska stopa za rastuće ekonomije viša nego što je za razvijene zemlje. Naime, rast takvih ekonomija temelji se na povećanju produktivnosti razmjenjivih dobara putem efikasnijeg korištenja zemlje, rada i kapitala što rezultira rastom plaća u nerazmjenjivom sektoru. Kako plaće rastu ljudi konzumiraju više dobara i usluga što rezultira općim povećanjem nivoa cijena.

[14] Održive javne financije obuhvaćaju dva kriterija: a) udio proračunskog deficita opće države u bruto domaćem proizvodu ne smije prelaziti 3%; b) udio bruto duga opće države u bruto domaćem proizvodu ne smije prelaziti 60%.

nije moguće bez određenog stupnja političke integracije. Europska integracija započela je s ekonomskom integracijom i s vremenom se proširila na monetarnu integraciju i neke oblike političke integracije.

U eurozoni skupina suverenih država dijeli zajedničku valutu, a u bliskoj budućnosti nije vjerojatno da će postati jedinstvena država u tradicionalnom smislu tog pojma (Mongelli, 2002). Zbog toga ovo predstavlja jedinstvenu situaciju koja zahtijeva da se politička integracija ocijeni prema više različitih mjerila. U kontekstu EU-a, Mongelli (2002) ističe tri aspekta političke integracije koje treba razmotriti:

- funkcionalna politička integracija - povećanje funkcionalne političke integracije postiže se putem Vijeća EU i Europskog parlamenta koji potiču usklađivanje nacionalnih zakona zemalja članica u nekoliko područja. Europska komisija inicira zajedničke politike i implementira nadnacionalne zakone i regulative, a Europski sud pravde daje jedinstvo europskom zakonu. Također, postoji poboljšani sustav multilateralnog nadzora i obvezujućih proračunskih obveza. Stoga zemlje EU-a već dijele određene elemente zajedničkog supranacionalnog ustavnog okvira. S druge strane, alokacijska uloga, redistribucija dohotka, stabilizacijska funkcija te promicanje rasta i zaposlenosti nije preneseno na nadnacionalnu razinu. U svakom slučaju, funkcionalna politička integracija povećat će se tijekom vremena kako se zakonski i regulatorni okvir te zajednički pogledi u kritičnim područjima budu dalje usklađivali.
- transfer suvereniteta pojedinih elemenata ekonomske politike - određeni elementi ekonomske politike centralizirani su na razini eurozone. Monetarna politika prepuštena je Europskom sustavu središnjih banka (ESCB) s Europskom centralnom bankom (ECB) na čelu. Politika deviznog tečaja prepuštena je ESCB-u i Vijeću EU-a koji zajedno odlučuju o okviru unutar kojeg se politika deviznog tečaja mora provoditi. ECB je odgovorna za upravljanje deviznim rezervama i provođenje operacija na deviznom tržištu. Mikroekonomska politika je također velikim dijelom centralizirana na razini Europske unije, posebice u područjima koje se tiču jedinstvenog tržišta, konkurencije i trgovinske politike. Osim toga, iako zemlje eurozone još uvijek imaju vlastitu fiskalnu politiku, moraju poštivati ograničenja definirana Paktom o stabilnosti i rastu.

- koordinacija politika - Europska unija zahtijeva veću koordinaciju politika koja se opravdava snažnijim političkim prelijevanjima između zemalja, prisutnosti ekonomije razmjera, nedjeljivosti nekih funkcija i mogućim koristima od udruživanja rizika. Izazov u kontekstu EU/EMU proizlazi u institucionalnom postavljanju jedinstvene monetarne politike i nekoliko nacionalnih nemonetarnih politika kod kojih se javlja problem međusobne koordinacije. Koordinacija na području EU/EMU uključuje multilateralni nadzor i čestu razmjenu stavova o politikama i razvoju specifičnih regija i unije u cjelini od strane nekoliko vijeća (ECOFIN, EPC i EFC). Također, koordinacija politika podrazumijeva česte konzultacije i sudjelovanja u radu glavnih nadnacionalnih institucija EU i razne oblike suradnje na konkretnim inicijativama i zajedničkim pravilima odlučivanja.

De Grauwe (2018) ističe da je tradicionalna teorija optimalnih valutnih područja poprilično pesimistična po pitanju pristupanja valutnom području uz niske troškove; smatra da su troškovi puno prihvatljiviji, i to iz dva razloga. Prvo, mogućnost korištenja deviznog tečaja u svrhu apsorpcije asimetričnih šokova je manja nego što to tradicionalna teorija optimalnih valutnih područja (koja je pod Keynesijanskim utjecajem) predmnijeva. Promjena devizog tečaja često nema trajni učinak na proizvodnju i zaposlenost. Drugo, umjesto da budu instrumenti makroekonomske stabilizacije, autonomna monetarna politika i politika deviznog tečaja često postaju izvor makroekonomskih poremećaja. Paradoksalno, volatilnost deviznog tečaja može biti značajan izvor asimetričnih šokova kod zemalja koje imaju vlastitu valutu. Dodatno, devizni tečaj nije instrument koji se može koristiti fleksibilno i bez troškova (De Grauwe, 2018).

Corden (1972) ističe da formiranje valutnog područja s grupom partnerskih zemalja podrazumijeva gubitak izravne kontrole nad nacionalnom monetarnom politikom i deviznim tečajem. To znači da zemlja pogođena negativnim šokom potražnje nema mogućnost korištenja monetarne politike i politike deviznog tečaja da bi olakšala prilagodbu relativnih plaća i cijena, već se cjelokupna prilagodba mora provesti: (i) povećanjem nezaposlenosti; (ii) smanjenjenjem plaća ili cijena; ili (iii) putem fiskalne politike. Za ključni kriterij formiranja valutnog područja ističe fleksibilnost cijena i plaća jer ga smatra bitnim za uspostavljanje ravnoteže u slučaju pojave asimetričnih šokova potražnje. Također, ističe važnost inflacije jer zemlje koje imaju različite inflacijske preferencije mogu imati dodatne troškove formiranjem valutnog područja.

Iako je Mundell (1963) skeptičan po pitanju uspješnog monetarnog integriranja Europe, u članku iz 1973. godine pruža potpuno novi (puno optimističniji) pogled na pristupanje valutnom području Naime, Mundell (1973) ističe da je u monetarnoj uniji moguće puno učinkovitije organizirati sustav osiguranja za borbu protiv asimetričnih šokova, nego je to moguće u sustavu nacionalnih valuta s nesigurnim deviznim tečajem. Autor navodi primjer privremenog asimetričnog šoka koji pogađa dvije zemlje. Kada dvije zemlje formiraju monetarnu uniju, postoje automatski tokovi kapitala koji će ublažiti udar na zemlju pogođenu negativnim šokovima. Ako su tržišta kapitala integrirana, potrošači jedne zemlje, koji znaju da je manjak dohotka privremen, a žele zadržati svoju razinu potrošnje, relativno lako mogu pozajmiti od potrošača druge zemlje (koji imaju privremeno povećanje dohotka). Ako ne postoji monetarna unija takav mehanizam bit će oslabljen jer različite valute i volatilni devizni tečaj otežavaju kreditiranje.

Dakle, za razliku od Mundella (1963) koji implicitno pretpostavlja učinkovita devizna tržišta u situaciji fleksibilnih tečajeva, Mundell (1973) implicitno pretpostavlja učinkovita međunarodna tržišta kapitala u situaciji fiksnih tečajeva. Mckinnon (2004) ističe da su 1950-ih i 1960-ih godina mnoge industrijske zemlje imale kapitalne kontrole koje su ograničavale mogućnost međunarodne podjele rizika, stoga ne iznenađuje činjenica da je Mundell (1963) ignorirao mogućnost diversifikacije portfelja kao način suočavanja s asimetričnim šokovima. Iako Mckinnon (2004) ističe da potpuno učinkovita tržišta kapitala ne postoje, još jednom se u teoriji optimalnih valutnih područja potvrđuje važnost financijske integracije (za borbu protiv asimetričnih šokova).

Ishiyama (1975) prepoznaje ograničenja u definiranju optimalnog valutnog područja uzimajući u obzir samo jedan kriterij. Ističe da bi svaka zemlja trebala analizirati koristi i troškove pristupanja valutnom području sa stajališta vlastitog interesa i dobrobiti. Kao važan kriterij optimalnog valutnog područja ističe sličnost stopa inflacije između zemalja.

Tower i Willett (1976) ističu da pristupanje valutnom području povećava korisnost novca, a učinak je jači što je zemlja manja i stupanj otvorenosti veći. Također, autori navode pozitivne učinke u pogledu učinkovitije alokacije resursa i povećanja učinkovitosti različitih funkcija novca (kao sredstva razmjene, obračunske jedinice i sredstva očuvanja vrijednosti). Istovremeno,

pristupanje ograničava mogućnost korištenja diskrecijske makroekonomske politike u svrhu postizanja unutrašnje ravnoteže.

Važnost realnog deviznog tečaja kao sveobuhvatnog i operativnog kriterija monetarnog integriranja ističe Vaubel (1976) prema kojem bi zemlje trebale formirati valutno područje ako nemaju potrebu mijenjati realni devizni tečaj (kroz promjene nominalnog deviznog tečaja). Realni devizni tečaj mijenja se istovremeno s promjenom uvjeta trgovine ili financijskih uvjeta[15]. Formiranjem valutnog područja ukidaju se promjene u valutnim preferencijama, ali rizik kreditiranja i promjene uvjeta trgovine i dalje će se događati i generirati promjene realnog deviznog tečaja između zemalja članica valutnog područja (Vaubel, 1976). Ako zemlje nemaju istu sklonost inflaciji, mogu biti previše različite da bi prihvatile napuštanje nominalnog deviznog tečaja kao instrumenta prilagodbe na vanjske neravnoteže.

Dellas i Tavlas (2009) ističu proturječnost i/ili nedosljednost rezultata analize optimalnog valutnog područja na temelju različitih OCA kriterija koja otežava jedinstveno definiranje domene optimalnog valutnog područja. Tako npr., zemlja može imati visoki stupanj otvorenosti prema grupi partnerskih zemalja što upućuje na korištenje fiksnog deviznog tečaja. Međutim, ista ta zemlja može imati nisku mobilnost faktora proizvodnje što znači da je za nju prihvatljiviji fleksibilni devizni tečaj. Slično tome, kriterij otvorenosti predlaže da bi male zemlje, koje su u pravilu relativno otvorene, trebale preferirati fiksni devizni tečaj. Iste te zemlje su vjerojatno manje diferencirane (u odnosu na velike ekonomije) pa bi po kriteriju stupnja diversifikacije prikladniji izbor za njih bio fluktuirajući devizni tečaj. Odnos između prikladnog deviznog režima i veličine ekonomije nije u potpunosti jasan, a princip diversifikacije vodi prema paradoksu (Dellas i Tavlas, 2009).

Dellas i Tavlas (2009) ističu da su autori tradicionalne faze teorije optimalnih valutnih područja zanemarili nekoliko važnih čimbenika koji značajno kompliciraju izbor prikladnog deviznog režima:

- priroda asimetričnih šokova;
- slobodnije kretanje kapitala;
- ograničenja fiskalne politike;

[15] Uvjeti trgovine pod utjecajem su promjene troškova rada i produktivnosti i/ili potražnje između zemalja; Financijski uvjeti pod utjecajem su promjene valutnih preferencija i rizika.

- razlike u stupnju ekonomskog razvoja između zemalja;
- manjkavi model koji ograničava primjenjivost OCA analize u stvarnim situacijama.

Apsorpcijski kapacitet režima deviznog tečaja je puno kompliciraniji nego što to pretpostavlja teorija optimalnih valutnih područja. Trošak fiksiranja deviznih tečajeva ovisi o prirodi i vrsti šokova kojima su zemlje izložene. Što je jači utjecaj realnih šokova, veće su koristi od fluktuirajućeg deviznog tečaja – ako je zemlja izložena šokovima agregatne potražnje, fluktuirajući devizni tečaj pružit će osiguranje od šokova neovisno o stupnju diversifikacije. Međutim, u slučaju privremenih šokova koristi od prilagodbe deviznog tečaja manje su nego što bi bile u slučaju trajnih šokova (Dellas i Tavlas, 2009).

Prilikom OCA analize nedovoljna pažnja posvećuje se prirodi šokova. Privremeni šokovi (nastaju kao rezultat kretanja poslovnih ciklusa) ne zahtijevaju relativne promjene cijena. Za razliku od njih, trajni šokovi (nastaju promjenom preferencija ili tehnologije (produktivnosti)) zahtijevaju relativne promjene cijena.

Međutim, trajni šokovi ne mogu se riješiti nacionalnom monetarnom politikom (koja uključuje politiku deviznog tečaja) jer su nacionalna valuta i devizni tečaj varijable koje ne mogu trajno promijeniti relativne cijene unutar ekonomije. Stoga, kod pojave trajnih šokova, devizni tečaj ne može biti ekonomski stabilizator kao što to pretpostavlja tradicionalna teorija optimalnih valutnih područja. Dodatno, čak je moguće da će kod pojave trajnih šokova korištenje vlastite valute i deviznog tečaja proces prilagodbe na dugoročnu ravnotežu biti skuplji nego u slučaju da se zemlja nalazi u valutnom području.

S druge strane, kod pojave privremenih šokova monetarnom politikom može se ugladiti amplituda poslovnog ciklusa. U skladu s time, trošak pridruživanja valutnom području ovisi o učinkovitosti monetarne politike kao instrumenta stabilizacije kod pojave navedenih šokova.

De Grauwe i Ji (2016) razlikuju asimetrične trajne (egzogene) šokove i asimetrične privremene (endogene) šokove. Ističu da se teorija optimalnih valutnih područja, koja je usredotočena na kompromis (engl. trade-off) između simetričnosti i fleksibilnosti, temelji na pretpostavci da su asimetrični šokovi trajni (i tipično egzogeni). Fleksibilnost je jedina mogućnost prilagodbe u slučaju pojave asimetričnih trajnih šokova. Međutim, kod pojave asimetričnih privremenih

šokova[16] nije prikladno koristiti fleksibilnost, već je u tom slučaju optimalno koristiti mehanizme osiguranja poput fiskalne unije. Dakle, činjenica da se zemlja suočava s asimetričnim šokovima nedovoljna je za zaključak je li ona prikladna za pristupanje valutnom području, već je potrebno detaljnije analizirati prirodu šokova. Ako su šokovi trajnog karaktera onda je za zemlju svejedno je li članica valutnog područja ili ne.

Dellas i Tavlas (2009) ističu da uvođenje kapitalnih tokova u OCA analizu mijenja rezultat originalnog Mundellovog modela – deficit tekućeg računa bilance plaćanja ne zahtijeva nužno deprecijaciju realnog deviznog tečaja jer porast produktivnosti inducira kapitalne priljeve putem kojih je moguće financirati deficit. Međutim, fluktuirajući devizni režim može uzrokovati volatilnost, nesigurnost i precjenjivanje/podcjenjivanje deviznog tečaja[17], što implicira da mobilnost kapitala može biti izvor asimetričnih šokova (kroz učinak na devizni tečaj). U sustavu fiksnih deviznih tečajeva špekulativno kretanje kapitala utječe na promjene deviznih rezervi te novčani i kreditni rast**.**

De Grawe (2018) smatra da je teorija optimalnih valutnih područja preoptimistična po pitanju mogućnosti apsorpcije negativnih šokova putem instrumenata fiskalne politike, i to iz tri razloga:

- sistematično korištenje fiskalnih instrumenata može dovesti do problema održivosti javnog duga. Posljedično, korištenje fiskalnih instrumenata u sadašnjosti ograničava njihovo korištenje u budućnosti;
- fiskalni transferi u situaciji pojave trajnih šokova mogu imati negativne učinke u pogledu zaključavanja resursa na jednom mjestu što sprječava nužnu prilagodbu;
- zemlja članica valutnog područja s visokim fiskalnim deficitom i udjelom duga u BDP-u može uzrokovati prelijevanje negativnih učinaka na ostale zemlje članice jer potiče rast kamatnih stopa na cijelom valutnom području što otežava financiranje javnog duga i u ostalim zemljama članicama.

Teorija optimalnih valutnih područja ne uzima u obzir (ne)prikladnost jedinstvene monetarne politike za zemlje na različitom stupnju ekonomskog razvoja. Naime, u monetarnoj uniji dviju zemalja, u kojoj središnja banka ima za cilj stabilnost cijena, zemlja na nižem stupnju razvoja (s

[16] Privremeni (endogeni) šokovi uzrokuju ciklička kretanja koja se sastoje od ekspanzija (u kojima prevladava optimizam) i kontrakcija (u kojima prevladava pesimizam)
[17] U situaciji kad devizni tečaj reflektira nefundamentalni šum (engl. non-fundamental noise)

nižim stupnjem dohotka po glavi stanovnika) suočava se s relativno višom očekivanom stopom povrata na investicije i nižim realnim (i nominalnim) kamatnim stopama. Slobodno kretanje kapitala u takvom okruženju stvara preoptimistična dohodovna očekivanja, uzrokuje pretjeranu domaću potražnju te potiče krivu strukturu investicija (npr. realizacija visokorizičnih investicijskih projekata koji se ne bi poduzeli u situaciji viših kamatnih stopa) u nerazvijenijoj zemlji. Posljedično, nerazvijenija zemlja će se suočiti s produljenom deflacijom u svrhu povraćanja konkurentnosti (Dellas i Tavlas, 2009).

Temeljna paradigma optimalnih valutnih područja djelomično je ravnotežna (engl. partial-equilibrium) i statična, a s obzirom na važnost učinaka prelijevanja i ekonomsku međuovisnost visoko integriranih zemalja, implikacije nacionalnih politika na svjetsko blagostanje trebale su biti uzete u obzir kod ranijih istraživanja, ali nisu (Dellas i Tavlas, 2009). Također, određeno je nekoliko ciljeva koji su neprecizno definirani[18], a odsustvo eksplicitne funkcije blagostanja otežava procjenu relativne važnosti kriterija optimalnog valutnog područja i donošenje zaključka o tome može li samo pristupanje valutnom području promijeniti strukturu ekonomije. Osim toga, tradicionalna teorija optimalnih valutnih područja nije pružila mehanizam za rješavanje problema nedosljednosti kriterija.

Teorija optimalnih valutnih područja služi kao konceptualni okvir za promišljanje o koristima i troškovima pridruživanja valutnom području, tj. prilikom analize monetarnog integriranja zemalja. Međutim, nakon početnog impulsa od dvadesetak godina, javlja se određeno razdoblje u kojem se teorija optimalnih valutnih područja ne pomiče s mrtve točke i njezin utjecaj počinje slabiti (Mongelli, 2002). Iako je omogućila važne početne spoznaje, Mongelli (2002) ističe da tradicionalna teorija optimalnih valutnih područja pruža uski i zastarjeli analitički okvir za definiranje optimalnog valutnog područja. Jedan od razloga usporavanja razvoja teorije optimalnih valutnih područja je nedostatak praktičnih primjera monetarnog integriranja i to posebno razvijenijih zemalja. Ponovni interes za teorijom javlja se devedesetih godina paralelno s razvojem ekonomske i monetarne unije (EMU). Mnoge je zanimao razvoj ovog velikog projekta i novi uvid u teoriju bio je potreban da bi se spoznalo je li eurozona stvarno optimalno valutno

[18] Neprecizno definiranje ciljeva otvara niz pitanja: Kako i kroz koje razdoblje se definirana vanjska ravnoteža? Zašto je stabilnost cijena cilj i kroz koje razdoblje ju treba postići? Kako se definira puna zaposlenost?

područje. Osim toga, razvoj na području makroekonomske teorije daje snažan poticaj - dolazi do razvoja moderne teorije optimalnih valutnih područja.

Za razliku od tradicionalne teorije optimalnih valutnih područja u kojoj su formirani poželjni kriteriji za fiksiranje tečaja (monetarno integriranje) i naglašavana troškovna strana, moderna teorija optimalnih valutnih područja orijentirana je prema koristima tj. dobrobitima valutnih područja. U modernoj fazi ponovno se aktualiziraju stara i detaljno obrađuju neka nova pitanja kao što su: učinkovitost i vjerodostojnost monetarne politike, simetričnost šokova, učinkovitost prilagodbe deviznog tečaja, usklađenost poslovnih ciklusa, teorija o endogenosti optimalnih valutnih područja, hipoteza o specijalizaciji, i sl.

Tradicionalna teorija optimalnih valutnih područja razvijena je u političkom i akademskom okruženju koje je veliki značaj pridavalo sposobnosti monetarnih autoriteta da dosegnu željenu točku na kratkoročnoj Philipsovoj krivulju, što implicira da u takvom okruženju gubitak monetarne politike predstavlja značajan trošak za zemlju. Međutim, svaki pokušaj monetarnih vlasti da smanjenje nezaposlenost povećanjem inflacije rezultirat će povećanjem inflacije u budućnosti uz istu stopu nezaposlenosti (Kunroo, 2015). Naime, privatni agenti, koji postavljaju svoja očekivanja o inflaciji u narednom razdoblju i oblikuju ugovore prema tim očekivanjima, osjećat će se prevarenima kad postanu svjesni djelovanja monetarnih autoriteta te će uključiti informacije u svoja inflacijska očekivanja za sljedeće razdoblje. Navedeni problem inflacijske pristranosti dovodi u pitanje kredibilitet monetarnih autoriteta, a alternativa je pridruživanje kredibilnom sustavu fiksnih deviznih tečajeva.

Buiter (1995) ističe važnost karaktera šokova koji pogađaju zemlju. Autor ističe da fleksibilnost nominalnog deviznog tečaja ima značajan utjecaj kod prilagodbe na realne šokove, ali ne i kod prilagodbe na financijske šokove. Dakle, kod dominacije financijskih šokova fiksni devizni tečaj pruža veću stabilnost, a kod dominacije realnih šokova poželjan je fluktuirajući devizni tečaj (Buiter, 1995).

Alesina, Barro i Trenyero (2002) ističu da su troškovi gubitka nezavisne monetarne politike manji što je veća sličnost šokova između zemlje klijenta (potencijalna zemlja članica valutnog područja) i zemlje sidra (zemlja za koju će klijent vezati valutu). Što su šokovi sličniji to će politika odabrana od strane zemlje sidra biti prikladnija zemlji klijentu. Autori ističu važnost

varijance outputa zemlje klijenta (u odnosu na varijancu outputa zemlje sidra) koja dijelom ovisi o povezanosti outputa, a dijelom od individualnih varijanci outputa. Tako na primjer, output Dominikanske Republike može biti visoko koreliran s outputom Sjedinjenih Američkih Država, ali ako je varijanca outputa Dominikanske Republike mnogo veća od varijance outputa SAD-a, tada će monetarna politika SAD-a biti neprikladna za Dominikansku Republiku.

De Grauwe (2018) ističe da prilikom pristupanja valutnom području treba uzeti u obzir različitost institucija tržišta rada zemalja. Autor navodi tri oblika centralizacije tržišta rada:

- tržišta rada na kojima dominiraju visoko centralizirani sindikati;
- tržišta rada na kojima su sindikati decentralizirani;
- intermedijarna tržišta rada.

Na tržištima pod dominacijom centraliziranih sindikata šok u ponudi neće dovesti do pretjeranog povećanja nominalnih plaća jer sindikati znaju da prekomjerno povećanje plaća vodi prema povećanoj inflaciji, što u konačnici čini realne plaće nepromijenjenima (De Grauwe, 2018).
Slična situacija je i s tržištima rada koja su visoko decentralizirana. Na takvim tržištima pregovaranje o plaćama zadržano je na razini poduzeća. Prekomjerno povećanje plaće (zbog šokova u ponudi) ima izravan utjecaj na konkurentnost poduzeća. Preveliki pritisak sindikata po pitanju povećanja plaća može dovesti do otpuštanja i zato sindikati nemaju poticaj za pregovaranje po tom pitanju.
S druge strane, intermedijarna tržišta rada imaju drugačiji pristup kod pojave šokova u ponudi. Na intermedijarnim tržištima rada sindikati će pojedinačno započeti pregovarački proces jer znaju da će njihov individualni postupak imati mali utjecaj na inflaciju, a u slučaju da to ne učine njihovi članovi će završiti s nižim realnim plaćama. Problem je u tome da će to učiniti svi sindikati što će za posljedicu imati povećanje nominalnih plaća i inflacije, pa će u konačnici realne plaće biti iste kao i prije povećanja.
Stoga zemlje s različitim stupnjem centralizacije tržišta rada mogu imati dodatne probleme prilikom pristupanja valutnom području (De Grauwe, 2018).

Teorija optimalnih valutnih područja preveliku važnost daje makroekonomskim troškovima s kojima se zemlje suočavaju prilikom formiranja valutnog područja, a s druge strane premalu pažnju poklanja koristima koje su većinom mikroekonomske prirode (Sanchis i Marco, 2014).

Koristi pristupanja valutnom području općenito se odnose na poboljšanje učinkovitosti na mikroekonomskoj razini, povećanje stabilnosti i rasta na makroekonomskoj razini te pozitivne vanjske učinke.

Povećanje mikroekonomske učinkovitosti rezultat je povećanja učinkovitosti novca kao: sredstva likvidnosti; obračunske jedinice; sredstva razmjene (zbog smanjenih transakcijskih troškova); sredstva za pohranu vrijednosti (zbog smanjene nesigurnosti); mjerila vrijednosti (zbog smanjenih informacijskih troškova); i sredstva za odgodu plaćanja. Veća cjenovna transparentnost obeshrabruje diskriminaciju cijena, smanjuje tržišnu diskriminaciju i potiče konkurentnost.

Povećanje makroekonomske stabilnosti odnosi se na: poboljšanje ukupne stabilnosti cijena; pristup širem i transparentnijem financijskom tržištu koje povećava dostupnost eksternog financiranja; reputacijske dobiti zemalja članica s višom inflacijom u prošlosti; i smanjenje nekih oblika fluktuacija outputa i nezaposlenosti diljem valutnog područja zbog različitih ekonomskih politika. Koristi od pozitivnih vanjskih efekata proizlaze iz: ušteda na transakcijskim troškovima širom međunarodnom cirkulacijom jedne valute; prihoda od međunarodne emisijske dobiti; smanjene potrebe za deviznim rezervama; i pojednostavljene međunarodne koordinacije.

Sanchis i Marco (2014) ističe nekoliko koristi od monetarnog integriranja zemalja:

- smanjenje rizika povezanih s volatilnošću i nesigurnošću zbog neočekivanih kretanja nominalnog deviznog tečaja;
- povećanje učinkovitosti koje proizlazi iz nižih kamata na investicije;
- povećanje izravne i neizravne učinkovitosti koje proizlazi iz eliminacije transakcijskih troškova povezanih s konverzijom valuta i troškova povezanih s informacijama o stranim cijenama;
- koristi od cjenovne stabilnosti;
- Smanjenje nesigurnosti pozitivno utječe na kretanja kapitala, izravne strane investicije, trgovinu i rast;
- ekonomske koristi koje proizlaze iz korištenja zajedničke valute kao rezervne valute (engl. reserve currency) i pokretačke valute (engl. vehicle curreny) za plaćanja u međunarodnoj trgovini;
- poticanje političke integracije.

Prihvaćanjem zajedničke valute nestaje valutni (tečajni) rizik. Valutnom riziku izloženi su svi ekonomski subjekti koji imaju neusklađenu valutnu strukturu imovine i obveza, te primitaka i izdataka, jer u slučaju promjene tečaja dolazi do promjene u neto vrijednosti njihove imovine. Problem je posebno izražen za ekonomske subjekte kod kojih je vrijednost obveza u stranoj valuti veća od imovine u stranoj valuti, jer kod njih deprecijacija dovodi do relativno snažnijeg povećanja duga.

Ukupan bruto devizni dug svih domaćih sektora u Hrvatskoj (uključujući i dug s valutnom klauzulom) premašuje 500 milijardi kuna, a valutnom riziku izloženi su svi domaći sektori: država (220 milijardi kuna deviznog duga), poduzeća (200 milijardi kuna deviznog duga) i stanovništvo (71 milijardu kuna deviznog duga). S obzirom na to da je više od 90 posto deviznog duga vezano uz euro, snažnija deprecijacija kune prema euru znatno bi povećala teret otplate duga. Tako bi npr. deprecijacija kune prema euru za 10 posto povećala devizni dug sektora opće države za 22 milijarde kuna, a uzimajući u obzir to da implicitna kamatna stopa na javni dug iznosi 3,9%, dodatni godišnji izdaci za kamate iznosili bi oko 850 milijuna kuna (Vlada Republike Hrvatske i HNB, 2018).

Uvođenjem eura u Hrvatsku značajno će se smanjiti regulatorni trošak za banke jer će se postojeći instrumenti monetarne politike HNB-a zamijeniti istovrsnim instrumentima ESB-a. Naime, stopa obvezne pričuve (koja u Hrvatskoj trenutno iznosi 12%) izjednačit će se sa stopom ESB-a koja iznosi 1%, uz izmjenu obuhvata. Dodatno, ukinut će se obveza održavanja minimalno potrebnih deviznih potraživanja (koja trenutno u Hrvatskoj iznosi 17% ukupnih deviznih obveza). Vlada Republike Hrvatske i HNB (2018) ističu da će navedene izmjene smanjiti regulatorni trošak s procijenjenih 0,45% (na kraju 2016.) na samo 0,01%, a kao posljedica smanjenja regulatornog troška mogle bi se smanjiti kamatne stope na bankovne kredite gospodarstvu.

Smanjenje volatilnosti deviznog tečaja snižava premiju rizika koju traže ulagači i na taj način potiče ulaganja na cijelom valutnom području. Zajednička valuta integrira nacionalna financijska tržišta što dovodi do veće učinkovitosti u raspodjeli kapitala. Osim toga, financijska imovina likvidnija je u valutnom području. Uklonjena neizvjesnost budućeg kretanja deviznog tečaja snižava također snižava premiju rizika koju plaćaju izdavatelji obveznica (Kopits, 1999). U srednjem roku taj učinak može biti povoljan za izdavatelje javnog duga jer smanjenje kamate može dovesti do većih javnih investicija ili potencijalno nižih poreza.

Kao jedna od najvećih koristi upotrebe zajedničke valute najčešće se ističe eliminacija transakcijskih troškova koji nastaju prilikom konverzije valuta. Što su veći trgovinski i financijski tokovi između zemalja, veće su koristi od smanjenja transakcijskih troškova. Patterson i Amati (1998) ističu da bi uvođenjem zajedničke valute uštede na transakcijskim troškovima mogle iznositi od 0,3% do 0,4% BDP-a zemalja, pri čemu bi najveću korist mogle imati male, otvorene i manje razvijene zemlje.

Međutim, gubitak troškova konverzije ne predstavlja čistu dobit ekonomske učinkovitosti. Uvođenjem zajedničke valute banke (i drugi subjekti koji su uključeni u devizne transakcije) doživjet će gubitak zbog nestanka prihoda od provizija. Međutim, dobitak za javnost veći je od gubitka banaka jer transakcijski troškovi uključeni u razmjenu novca predstavljaju mrtvi teret (De Grauwe 2018).

Eliminacija transakcijskih troškova stvara i neizravnu dobit u obliku veće transparentnosti cijena. Naime, novac ne služi samo kao sredstvo razmjene, već i kao obračunska jedinica. U valutnom području postoji jedinstvena obračunska jedinica koja olakšava usporedbu cijena i plaća preko nacionalnih granica. Upotreba zajedničke valute čini tržišta transparentnijima, smanjuje troškove obrade podataka i diskriminaciju cijena između nacionalnih tržišta. Izravna usporedivost cijena povećava konkurenciju, a to u konačnici koristi potrošačima jer će imati niže cijene.

Uvođenjem eura u Hrvatsku nestat će transakcijski troškovi konverzije kuna u eure (i obratno) koji proizlaze iz razlike kupovnoga i prodajnoga tečaja te naknada i provizija banaka i mjenjačnica pri obavljanju konverzije. Vlada Republike Hrvatske i HNB (2018) procjenjuju transakcijski trošak domaćih sektora kućanstva i poduzeća na razini 0,1% do 0,3% BDP-a na godišnjoj razini, što je u skladu s procjenama drugih zemalja koje su uvodile euro.

Osim toga, Silva i Tenreyro (2010) ističu da manji transakcijski troškovi i eliminacija rizika deviznog tečaja potiču stvaranje dubljih i likvidnijih financijskih tržišta koja povećavaju alokacijsku učinkovitost kapitala i omogućavaju diversifikaciju šokova s ciljem ublažavanja njihovog utjecaja na potrošnju.

Valutno područje pridonosi smanjenju špekulativnih napada prema zemljama članicama. Kod intermedijarnih deviznih sustava špekulanti mogu testirati paritet tečaja trgujući velikim količinama valuta. Središnja banka će zadržati tečaj unutar granica intervencijama na tržištu sve

dok ima dovoljno velike devizne rezerve. Ako rezerve nisu dostatne paritet se neće moći obraniti i tržišna očekivanja će se ispuniti. Dodatno, pod pretpostavkom nesavršenih tržišta kapitala, monetarno integriranje smanjuje mogućnost da će špekulativne tržišne snage usmjeriti valutu daleko od svoje fundamentalne vrijednosti jer zajednička središnja banka raspolaže većim rezervama nego pojedinačne središnje banke.

Silva i Tenreyro (2010) kao važnu korist pristupanja valutnom području ističu smanjenje stope inflacije, što je posebno važno za zemlje s nedostatkom interne discipline i institucija koje osiguravaju okruženje s niskom i stabilnom inflacijom. Pridruživanjem valutnom području s kredibilnom zemljom sidrom (engl. anchor country), takve zemlje će eliminirati inflaciju koja proizlazi iz vremenske nedosljednosti u provođenju monetarne politike. Stoga zemlje koje su u prošlosti imale visoku stopu inflacije imaju veću korist od pristupanja valutnom području, pod pretpostavkom da im zemlje s niskom inflacijom služe kao sidro.

Smanjenje nesigurnosti pozitivno utječe na kretanja kapitala, izravne strane investicije, trgovinu i rast (Sanchis i Marco, 2014). Naime, odluke o potrošnji, štednji i investicijama mogu biti iskrivljene ako postoji nekoliko valuta jer ekonomski agenti ne mogu u potpunosti iskoristiti prednosti jedinstvenog tržišta. Također, postoje potencijalne koristi koje proizlaze iz utjecaja izravnog povećanja produktivnosti na povećanje zaliha kapitala tijekom vremena (Sanchis i Marco, 2014).

Konačno, korištenje zajedničke valute može dovesti do povećanja međunarodne trgovine. Učinak poticanja trgovine kojeg promovira zajednička valuta može biti vrlo značajan i mnogo veći nego što bi se očekivalo od smanjenja transakcijskih troškova i uklanjanja volatilnosti tečaja.

S druge strane, troškovi pristupanja valutnom području općenito se odnose na pogoršanje mikroekonomske učinkovitosti, smanjenje makroekonomske stabilnosti i negativne vanjske utjecaje.

Pogoršanje mikroekonomske učinkovitosti odnosi se na prelazak na novu valutu. Uvođenje zajedničke valute zahtijeva nove novčanice i kovanice, a istovremeno se stara valuta treba povući iz opticaja. Potrošači i ostali gospodarski subjekti moraju konvertirati cijene i plaće u novu valutu. Također, javljaju se troškovi ažuriranja softvera, zamjene ili prilagodbe automata, bankomata i sl. Osim administrativnih, pravnih i „hardverskih“ troškova javljaju se i psihološki

troškovi koji će sporije nestati. Konačno, gospodarski subjekti trebaju se priviknuti na prikupljanje podataka i izradu kalkulacija u novoj obračunskoj jedinici.

Sanchis i Marco (2014) ističe glavne troškove monetarnog integriranja:

- gubitak autonomne monetarne politike;
- smanjena mogućnost korištenja emisijske dobiti (engl. seigniorage);
- divergentne preferencije zemalja kod međuodnosa inflacije i zaposlenosti (Phillipsova krivulja);
- povećanje regionalnih neravnoteža.

Značajni trošak pristupanja valutnom području predstavlja gubitak vlastite monetarne politike i politike deviznog tečaja. Naime, pod pretpostavkom da devizni tečaj reagira dovoljno brzo i točno na fundamentalne promjene, zemlja će napuštanjem fluktuirajućeg deviznog tečaja izgubiti vrlo važan instrument stabilizacije Međutim, kvantitativna procjena ovog troška je iznimno teška jer postoji mnogo čimbenika koji utječu na potrebu korištenja i učinkovitost monetarne politike kao mehanizma prilagodbe. Dakle, pristupanjem valutnom području sužava se izbor instrumenata izravno dostupnih nacionalnim vladama kod pojave šokova jer se odgovornost za izbor monetarne politike prenosi se na nadnacionalnu središnju banku pa ni jedna zemlja ne može provoditi realne prilagodbe u slučaju asimetričnih šokova.

Ako zemlja izabere krivi paritet nominalnog deviznog tečaja prilikom uvođenja zajedničke valute, može biti nekonkurentna ili prekonkurentna s obzirom na ostale zemlje članice. Neravnoteža na vanjskim računima vjerojatno će ustrajati sve dok se struktura cijena i plaća te razina gospodarske aktivnosti u zemlji ne prilagodi drugim zemljama članicama.

Uvođenje zajedničke valute stvara potrebu za nadnacionalnom institucijom. To će rezultirati povećanim administrativnim troškovima zemalja članica koji bi mogli biti podmireni smanjenjem veličine nekih državnih institucija zbog preraspodjele i dijeljenja funkcija.

Dalje, ako zemlja ima rigidnije nominalne cijene i plaće od ostalih zemalja članica, niža stopa inflacije na tom području može povećati nezaposlenost (dok se rigidnost ne smanji strukturnim reformama). To može dovesti do izraženijih kratkoročnih fluktuacija outputa i nezaposlenosti.

Potencijalni trošak monetarnog predstavlja smanjenje emisijske dobiti (engl. seignorage). Sanchis i Marco (2014) ističe da je korištenje emisijske dobiti, unatoč inflacijskim posljedicama, vrlo učinkovit način bijega od problema pretjeranog duga. Kod zemlje s visokom inflacijom u prošlosti, monetarno integriranje sa stabilnijim zemljama smanjit će prihode koji proizlaze iz emisije novca. Ovo je osobito važno za zemlje s nerazvijenim poreznim sustavom kod kojih je inflacijski porez poželjan. Pod pretpostavkom iste javne potrošnje, smanjenje prihoda će zahtijevati veći proračunski deficit ili kompenzaciju putem fiskalnih transfera.

Troškovi mogu nastati i zbog djelovanja Balassa-Samuelsonovog efekta. Divergente stope rasta u zemljama valutnog područja mogu dovesti do trajne nestabilnosti u nacionalnim stopama inflacije. Naime, kod monetarnog integriranja razvijenijih s manje razvijenim zemljama, zbog liberalizacije trgovine i stranog konkurentskog pritiska, manje razvijene zemlje će vjerojatno imati višu stopu inflacije nego razvijenije države.

Važan mehanizam uspostavljanja ravnoteže predstavljaju fiskalni transferi (fiskalna redistribucija sredstava među zemljama članicama). Ako valutno područje ne uključuje fiskalnu uniju i/ili ako budžet nije dovoljno velik, onda su fiskalni transferi ograničeni. Mehanizam fiskalnih transfera posebno je značajan ako su zemlje pogođene asimetričnim šokovima. U slučaju da fleksibilnost plaća, faktorska mobilnost i fiskalni transferi ne mogu ugladiti šokove, monetarno integriranje može uzrokovati značajne troškove.

Osim toga, zajednička fiskalna ograničenja (npr. Pakt o stabilnosti i rastu; Procedura prekomjernog deficita) mogu otežati provođenje nacionalne fiskalne politike, pogotovo u zemljama s relativno visokim javnim dugom i/ili visokim proračunskim deficitom.

Konačno, ako zemalja članica ima dugotrajan i značajan proračunski deficit kojim se gomila neodrživi javni dug, negativne eksternalije mogu se proširiti na cijelo valutno područje zbog straha da će takav dug biti unovčen. To može uzrokovati pritisak na kamatne stope valutnog područja, a potencijalno i međunarodni gubitak povjerenja u valutu. U takvom scenariju svaka zemlja članica će patiti, a osobito one koje su prethodno imale stabilne valute.

2.2. Teorijski doprinosi teorije optimalnih valutnih područja

Tradicionalna teorija optimalnog valutnog područja identificirala je kriterije (karakteristike) koje zemlja treba zadovoljiti prije pristupanja valutnom području (*ex ante*), tj. pretpostavljala je da područje mora biti optimalno prije monetarnog integriranja (fiksiranja deviznog tečaja). S druge strane, moderna teorija optimalnog valutnog područja fokusirana je na promjene u ekonomskoj strukturi koje proizlaze iz sudjelovanja u valutnom području (*ex post*).

Pitanje koje se često postavljalo u literaturi je sljedeće: hoće li uvođenje zajedničke valute pridonijeti usklađivanju poslovnih ciklusa ili će potaknuti njihovu divergenciju? S čisto teorijskog gledišta, odgovor nije jednoznačan (Gachter i ostali, 2012). U tom kontekstu, važan teorijski doprinos teoriji optimalnih valutnih područja daju dvije međusobno suprotstavljene hipoteze: hipoteza o endogenosti (Frankel i Rose, 1998) i hipoteza o specijalizaciji (Krugman, 1993). Osnovni zaključak koji se nameće detaljnijom analizom navedenih hipoteza je da statička analiza svakog kriterija zasebno nije dovoljna za procjenu koristi i troškova monetarnog integriranja, već je potrebno analizirati odnose između kriterija. U nastavku su prikazane osnovne postavke hipoteze o endogenosti i hipoteze o specijalizaciji.

2.2.1. Hipoteza o endogenosti

Prilikom prosudbe o monetarnom integriranju europskih zemalja najčešće se analizira nekoliko kriterija i radi usporedba s SAD-om kao benchmark zemljom. Ovakva procedura je neprihvatljiva jer su OCA kriteriji zajednički endogeni (engl. jointly endogenous). Stoga se odluka o monetarnom integriranju zemalja ne može donijeti na temelju analize povijesnih podataka jer će se struktura ovih ekonomija vjerojatno drastično promijeniti samim pristupanjem u EMU (Frankel i Rose, 1998).

Ne umanjujući važnost mobilnosti rada i podjele rizika (putem fiskalnih transfera), Frankel i Rose (1998) fokusiraju se na trgovinsku otvorenost i usklađenost poslovnih ciklusa kao dva ključna OCA kriterija.

Zemlje koje pristupe valutnom području (bez obzira na njihov motiv) mogu zadovoljiti OCA kriterije nakon ulaska, iako te iste kriterije nisu zadovoljile prije ulaska u valutno područje. Dakle, granice valutnog područja mogu se proširiti u očekivanju da će se samim ulaskom u valutno područje povećati trgovinska integracija i korelacija dohodaka (Frankel i Rose, 1998). Ovaj učinak Frankel i Rose (1998) nazivaju endogenost optimalnog valutnog područja.

Korist prihvaćanja zajedničke valute rastuća je funkcija trgovinske integracije i usklađenosti poslovnih ciklusa zbog čega je OCA linija (prikazana na slici 2.) negativnog nagiba. Grupa zemalja koja se nalazi poviše OCA linije (na slici u desnom gornjem uglu) trebala bi imati zajedničku valutu jer koristi prihvaćanja zajedničke valute nadilaze troškove gubitka monetarne neovisnosti. S druge strane, grupi zemalja koje se nalaze ispod OCA linije (na slici u lijevom donjem uglu) isplatljivije je zadržati vlastitu valutu jer su troškovi gubitka vlastite valute veći od koristi koje proizlaze iz monetarnog integriranja.

Slika 2. Trgovinska integracija, usklađenost poslovnih ciklusa i izbor monetarnog režima

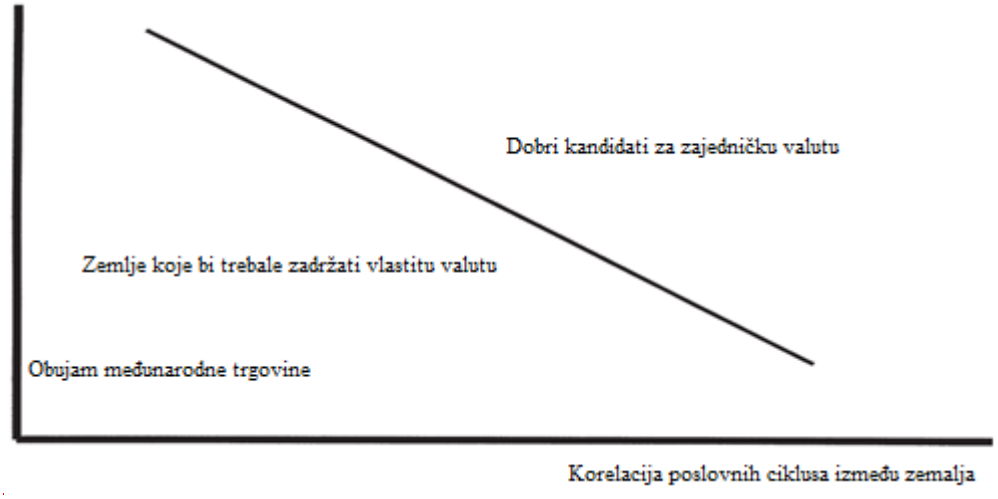

Izvor: Prilagođeno prema Frankel i Rose (1998)

Stoga se stupanj integracije između potencijalnih zemalja članica ne bi trebao promatrati odvojeno od korelacije dohodaka jer usklađenost poslovnih ciklusa ovisi o trgovinskoj integraciji (Frankel i Rose, 1998).

Frankel i Rose (1998) navode sljedeći primjer: Početna pretpostavka je da postoji skupina zemalja koja se inicijalno nalazi u točki 1. na slici 3. (lijevo od OCA linije). Ako navedene

zemlje formiraju uniju (npr. EU), trgovinska integracija i korelacija dohodaka će se povećati i zemlje će postupno prijeći na točku 2. Ako iste zemlje formiraju valutno područje (npr. EMU), stupanj trgovinske integracije i korelacije dohodaka dodatno će narasti i zemlje će se naći s desne strane OCA linije. Mongelli (2002) ističe da Frankel-Roseova pretpostavka ima važne implikacije za monetarno integriranje jer se prikladnost neke zemlje za pristup valutnom području mora ponovo razmotriti ako je zadovoljenje kriterija optimalnog valutnog područja endogeno.

Slika 3. Endogenost optimalnog valutnog područja

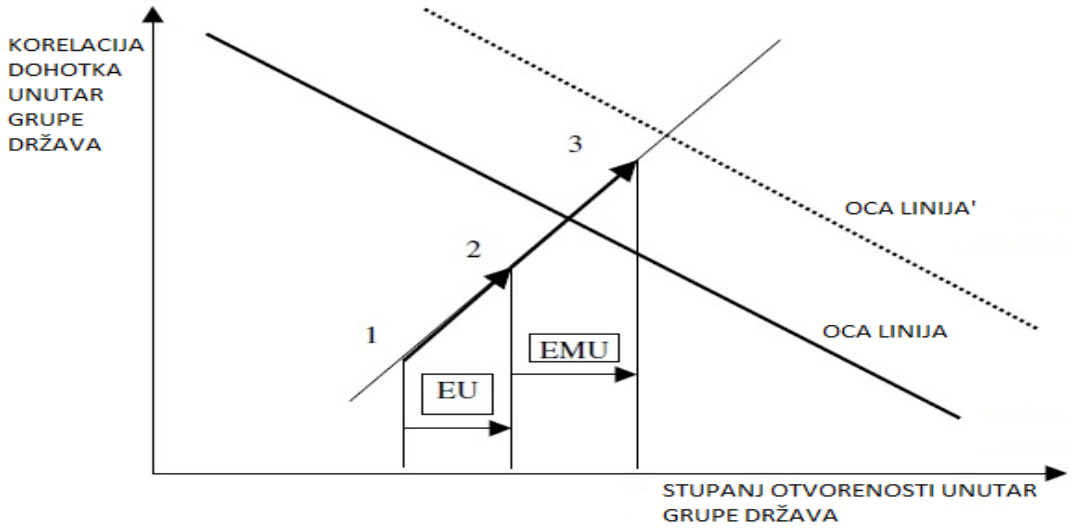

Izvor: Prilagođeno prema Mongelli (2002)

Za razliku od ranije literature o optimalnim valutnim područjima koja je usmjerena prema asimetričnim šokovima između zemalja kao kriteriju za prikladnost pristupanja valutnom području, literatura o endogenosti optimalnog valutnog područja implicira da će se pristupanjem valutnom području smanjiti učestalost pojave asimetričnih šokova između partnerskih zemalja (Dellas i Tavlas, 2009).

Hipoteza o endogenosti optimalnog valutnog područja trebala bi se se protumačiti u širem kontekstu. Naime, endogenost je povezana s napretkom u mnogim OCA kriterijima koji su neophodni za uspješno funkcioniranje valutnog područja. Takav napredak nije uvijek linearan, već je nadogradnja prethodne faze. Stoga analiza endogenosti optimalnog valutnog područja ne bi

trebala biti ograničena samo na trgovinsku integraciju i korelaciju dohodaka, nego bi je trebalo proširiti i na druge kriterije.

De Grauwe i Mongelli (2005) endogenost optimalnog valutnog područja definiraju kao skup interaktivnih procesa koji poboljšavaju OCA rejting valutnog područja. Autori ističu da trgovina nije jedini izvor endogenosti optimalnog valutnog područja. U skladu s empirijskom literaturom ističu četiri osnovna izvora endogenosti optimalnog valutnog područja:

- endogenost ekonomske (trgovinske) integracije - valutno područje potiče trgovinske tokove (intenzivira trgovinsku integraciju) i na taj način povećava koristi od monetarnog integriranja;
- endogenost financijske integracije tj. shema osiguranja putem tržišta kapitala - monetarna integracija potiče financijsku integraciju čime olakšava nastanak mehanizama osiguranja koji smanjuju troškove asimetričnih šokova;
- endogenost simetričnosti šokova i usklađenosti outputa;
- endogenost fleksibilnosti tržišta proizvoda i rada - valutno područje utječe na tržište rada na način da može povećati njegovu fleksibilnost čime se smanjuju troškovi prilagodbe na asimetrične šokove u valutnom području.

Navedeni mehanizmi pomiču valutno područje prema optimalnom valutnom području. Dakle, prema hipotezi o endogenosti optimalnog valutnog područja kriteriji optimalnog valutnog područja mogu biti zadovoljeni *ex post* iako to nisu *ex ante*. Učinak ovih mehanizama može biti kvantitativno vrlo jak (Rose i Wincoop, 2001).

Procjena trgovinskih dobitaka od monetarnog integriranja, tj. snaga endogenosti optimalnog valutnog područja putem trgovinske integracije pokazuje velike varijacije kroz studije. Rose i ostali (2000) ističu da postoji snažni pozitivni učinak valutnog područja na međunarodnu trgovinu. Naime, korištenjem gravitacijskog modela na uzorku od 186 zemalja u razdoblju od 1970. do 1990. godine autori potvrđuju da zemlje koje dijele zajedničku valutu trguju tri puta više nego su to činili s različitim valutama. Frankel i Rose (2002) proširili su uzorak na 200 država i zaključili da valutno područje više od tri puta povećava trgovinu među zemljama članicama. Njihovi rezultati robusni su na uključivanje jezičnih, povijesnih i političkih veza. Rose i Wincoop (2001) ističu da bi eurozona potaknula unutrašnju trgovinu za nešto više od 50%, što je znatno

manja procjena od Frankela i Rosea (2002). Istraživanja Melitza (2001) i Perssona (2001) pokazuju još niže procjene. Persson (2001) smatra da bi monetarno integriranje donijelo 13-40 posto povećanja trgovinske razmjene, dok je Melitzova (2001) procjena nešto veća. Alesina, Barro i Tenreyro (2002) primijenili su drugačiju metodologiju i potvrdili da valutno područje povećava konvergenciju cijena i eventualno output.

2.2.2. Hipoteza o specijalizaciji

Suprotno hipotezi o endogenosti optimalnog valutnog područja, Krugman (1993) postavlja hipotezu o specijalizaciji koja svoje korijene ima u teoriji međunarodne razmjene. Hipoteza o specijalizaciji implicira da kako zemlje postaju integriranije (i njihova međusobna otvorenost raste), specijalizirat će se u proizvodnji onih dobara i usluga u kojima imaju komparativne prednosti. Na taj način postat će manje diversificirane (specijaliziranije) i osjetljivije na šokove ponude. U skladu s time, njihovi međusobni prihodi bit će manje korelirani.

Na slici 4. prikazan je utjecaj specijalizacije na optimalnost valutnog područja prema hipotezi o specijalizaciji. Povećanje integracije pomiče zemlje dalje od OCA linije, tj. od točke 1. prema točki 2. koja predstavlja veću otvorenost i manju korelaciju dohodaka između zemalja. U točki 2. dominiraju prednosti korištenja vlastite valute i autonomne monetarne politike.

Slika 4. Hipoteza o specijalizaciji

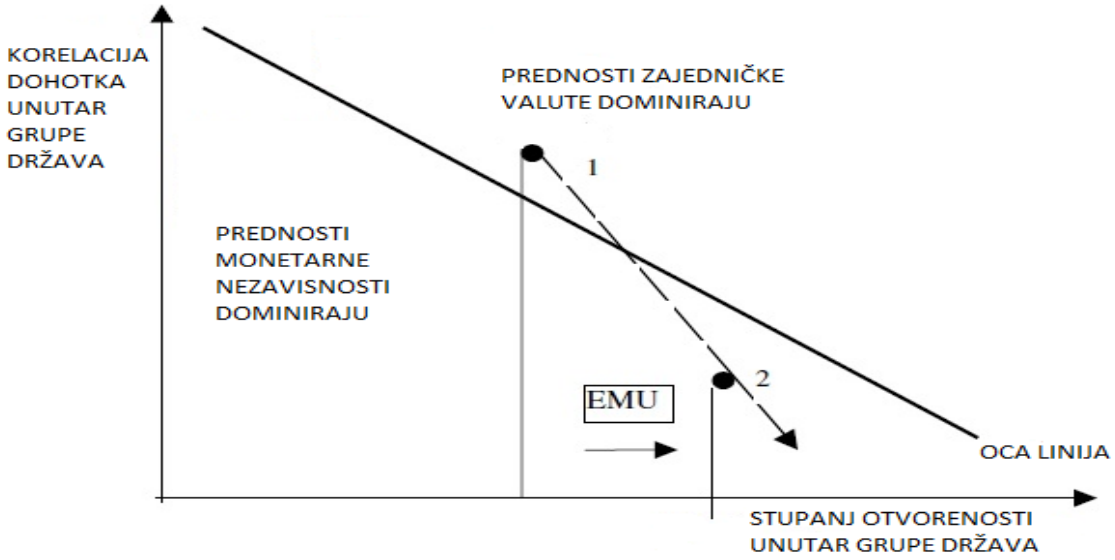

Izvor: Prilagođeno prema Mongelli (2002)

Kalemli-Ozcan, Sorensen i Yosha (2003) potvrđuju da financijska integracija (putem podjele rizika) potiče specijalizaciju u proizvodnji. Eichengreen (1996) uspoređuje razvoj osam industrijskih sektora diljem Europe i SAD-a te potvrđuje povećanje specijalizacije u Europi i smanjenje specijalizacije u SAD-u. Europska komisija (1999) navodi da postoji dokaz rastuće specijalizacije, ali padajuće koncentracije. Države EU su sve više specijalizirane jer se usredotočuju na aktivnosti u kojima su relativno jače, dok industrije postaju manje koncentrirane, tj. više distribuirane diljem zemlje. Ipak, Europska komisija ističe kratko vremensko razdoblje studije (1988-1998) i potrebu da se preliminarni nalazi nadopune daljnjom analizom.

Mongelli (2002) navodi da je Frankel uočio paradoks argumenta da integracija potiče specijalizaciju i čini zemlje neprikladnim partnerima za valutno područje. Naime, ako je ključan čimbenik diversifikacija, onda se problem može riješiti širenjem granice optimalnog valutnog područja jer su veći geografski subjekti diversificiraniji. Ako umjesto toga grupa zemalja nije dovoljno diversificirana, onda one ne bi trebale dijeliti jednu valutu nego bi se umjesto toga trebale podijeliti u manje jedinice između kojih devizni tečaj fluktuira. Ali ove manje jedinice će biti još manje diversificirane i trebale bi se podijeliti u još manje jedinice. Proces podjele će se nastaviti sve dok se svijet ne dovede do razine potpuno specijaliziranih individua. Dakle, sistem je nestabilan i ne postoji interno rješenje; međutim, ovakav paradoks se ne promatra u stvarnosti.

2.3. Pojam i važnost usklađenosti poslovnih ciklusa za provođenje zajedničke monetarne politike

Već je ranije naglašeno da su u ranoj fazi teorije optimalnih valutnih područja definirani poželjni kriteriji koje bi zemlje trebale zadovoljiti da bi postale optimalno valutno podruje. U kasnijoj fazi, dodatno na postojeće kriterije, razvijen je kriterij koji implicitno sumira OCA kriterije – usklađenost poslovnih ciklusa (Gachter i ostali, 2012).

Usklađenost poslovnih ciklusa neophodna je za normalno funkcioniranje valutnih područja. Što su usklađeniji poslovni ciklusi zemalja u monetarnoj uniji, lakše je središnjoj banci provesti stabilizacijsku politiku (Clarida i ostali, 1999). Dodatno, Altavilla (2004) ističe da visoki stupanj usklađenosti između poslovnih ciklusa smanjuje vjerojatnost širenja asimetričnih šokova među

zemljama valutnog područja. Eichengreen (1993) zaključuje da su troškovi napuštanja vlastite monetarne politike posebno visoki ako su poslovni ciklusi zemalja slabo korelirani i alternativni mehanizmi prilagodbe poput faktorske mobilnosti nedovoljno dostupni. Dakle, što su poslovni ciklusi usklađeniji, manji su troškovi napuštanja vlastite monetarne politike (Belke i ostali, 2017).

Kao jednu od najvećih koristi korištenja vlastite valute literatura ističe mogućnost uglađivanja poslovnih ciklusa putem vlastite anticikličke monetarne politike. S obzirom na to da se monetarnim integriranjem zemlje odriču vlastite monetarne politike (koja se zajednički definira na razini valutnog područja), nužan uvjet za monetarno integriranje je postojanje visokog stupnja usklađenosti poslovnih ciklusa zemalja.

Gachter i ostali (2012) smatraju usklađenost poslovnih ciklusa najvažnijim kriterijem optimalnih valutnih područja. Visoki stupanj usklađenosti poslovnih ciklusa predstavlja pozitivni indikator za valutno područje jer ukazuje na to da će zajednička monetarna politika biti prikladna za sve zemlje članice (Artis, Marcellino i Proietti, 2003). Stoga se kriterij usklađenosti poslovnih ciklusa intenzivno primjenjuje prilikom analize koristi i troškova monetarnog integriranja novih zemalja članica EU (Fidrmuc i Korhonen, 2006).

Usklađeni poslovni ciklusi istovremeno se kreću kroz iste faze ciklusa ekonomske aktivnosti, tj. istovremeno prolaze kroz ekspanzije, recesije, usporavanja i ubrzanja ekonomske aktivnosti (Globan, 2018). Samo u slučaju da poslovni ciklusi zemalja imaju isti tajming, smjer i magnitudu, središnja banka može provoditi učinkovitu monetarnu politiku (Antonakakis i Tondl, 2014).

Kod mjerenja usklađenosti poslovnih ciklusa većina istraživanja fokusira se na korelaciju poslovnih ciklusa. Belke i ostali (2017) ističu da to može biti obmanjujuće ako su amplitude poslovnih ciklusa značajno različite. Stoga su u nastavku prikazane i objašnjene tri situacije (slika 5., 6. i 7.) koje su ključne za razumijevanje problematike koncepta usklađenosti poslovnih ciklusa.

Na slici 5. prikazani su poslovni ciklusi zemalja koji imaju savršenu faznu usklađenost, ali su njihove amplitude različite. Ove razlike u amplitudama mogu dovesti do sličnih problema u vođenju zajedničke monetarne politike kao i u slučaju da su poslovni ciklusi zemalja fazno neusklađeni. Naime, problemi s različitim amplitudama javljaju se uglavnom oko ekstrema

poslovnog ciklusa (vrha i dna poslovnog ciklusa). Korelacija kao mjera usklađenosti poslovnih ciklusa u ovom slučaju nema puno smisla, pogotovo ako je amplitudna razlika između poslovnih ciklusa zemalja velika.

Na slici 6. prikazani su poslovni ciklusi zemalja koji su pomaknuti u vremenu (fazni pomak). U ovom slučaju korelacija je niska iako su razlike u cikličkim pozicijama minimalne i ostaju konstante između vrha i dna. Dakle, moguće je da kod minimalnog faznog pomaka (koji ne mora nužno uzrokovati velike probleme u provođenju zajedničke monetarne politike) korelacija iskrivljuje sliku o stupnju usklađenosti poslovnih ciklusa. U ekstremnom slučaju (kod faznog pomaka za točno pola ciklusa) korelacija je jednaka nuli.

Slika 5. Savršena fazna usklađenost poslovnih ciklusa s različitim amplitudama

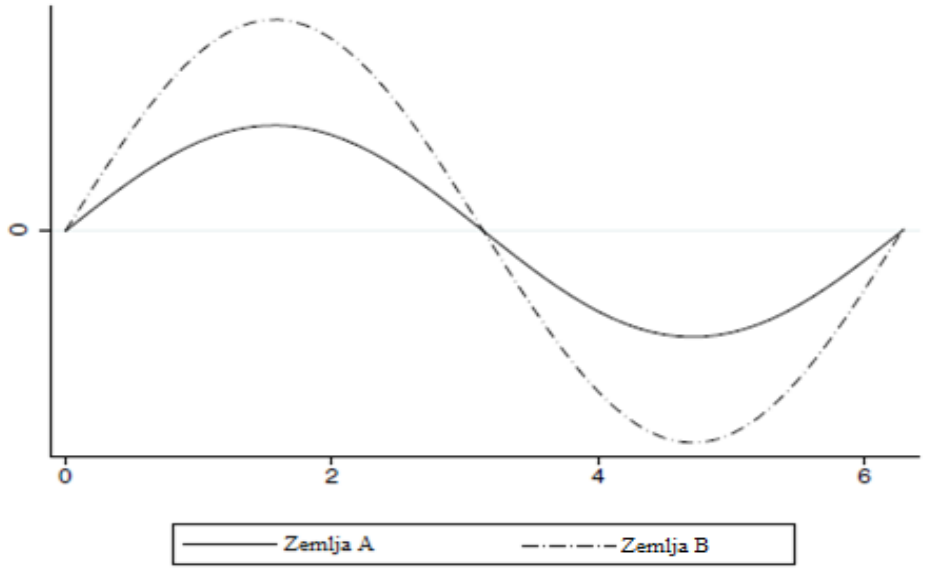

Izvor: Belke, Domnick i Gros (2017)

Slika 6. Niska korelacija zbog faznog pomaka

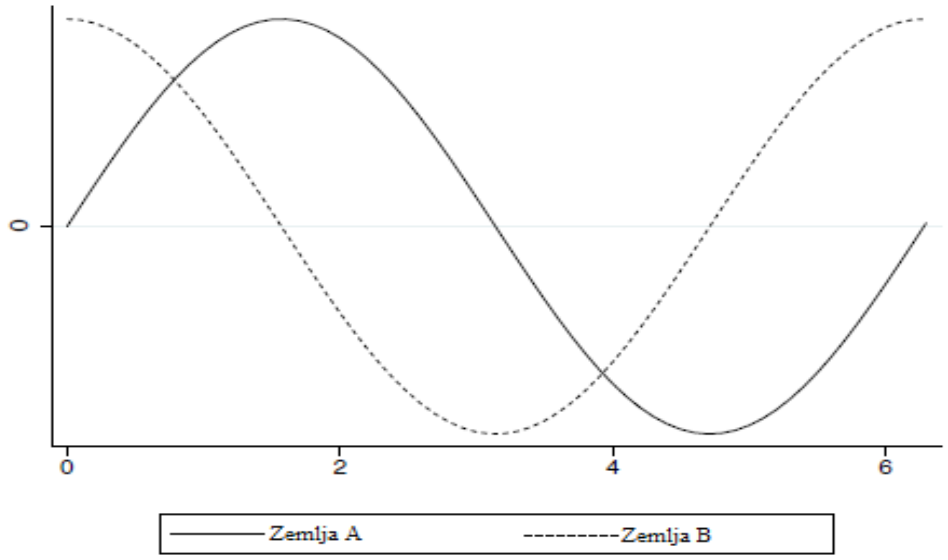

Izvor: Belke, Domnick i Gros (2017)

Na slici 7. prikazana su tri poslovna ciklusa: referentni ciklus (npr. zajednički poslovni ciklus eurozone); ciklus zemlje A koji ima fazni pomak, ali ima istu amplitudu kao eurozonski ciklus; i poslovni ciklus zemlje B koji ima jednaki fazni pomak kao i zemlja A, ali dvostruko veću amplitudu od referentnog ciklusa. Očigledno je da mora postojati razlika u stupnju usklađenosti poslovnih ciklusa zemalja A i B s referentnim ciklusom jer je amplituda poslovnih ciklusa zemalja A i B različita, međutim korelacijski koeficijent između referentnog ciklusa i poslovnih ciklusa zemalja A i B jednak je u oba slučaja.

Iako Belke i ostali (2017) ističu važnost amplitudne razlike kao ključnog čimbenika za provođenje zajedničke monetarne politike, iz prikazanih slika očigledan je nedostatak mjerenja usklađenosti poslovnih ciklusa korelacijskim koeficijentom koji zanemaruje amplitudnu razliku poslovnih ciklusa.

Slika 7. Različita amplituda i fazni pomak

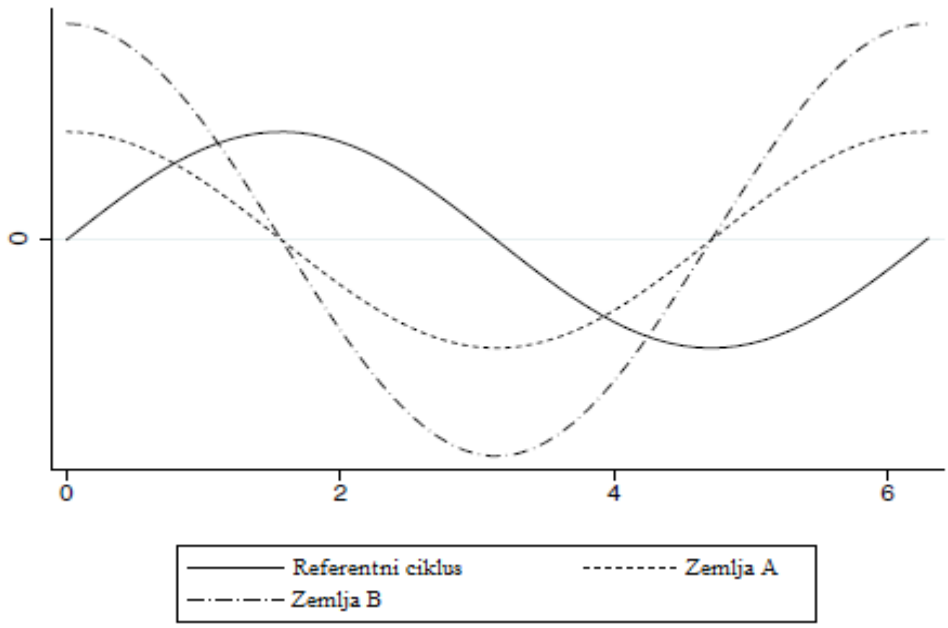

Izvor: Belke, Domnick i Gros (2017)

Mjerenje usklađenosti poslovnih ciklusa podrazumijeva korištenje metodologije koja se sastoji od tri osnovna koraka:

- izbor indikatora ekonomske aktivnosti;
- izbor metode procjene poslovnih ciklusa zemalja;
- izbor mjere usklađenosti poslovnih ciklusa.

U nastavku su prikazani indikatori ekonomske aktivnosti, metode procjene poslovnih ciklusa i različite mjere usklađenosti poslovnih ciklusa korištene u dosadašnjim istraživanjima te navedene njihove prednosti i ograničenja, a sve u svrhu formiranja optimalne metodologije za mjerenje usklađenosti poslovnog ciklusa Hrvatske s poslovnim ciklusima zemalja eurozone.

2.3.1. Definiranje poslovnih ciklusa

Prije analize metodologije mjerenja usklađenosti poslovnih ciklusa potrebno je prvo definirati poslovne cikluse. Naime, prvi korak u mjerenju usklađenosti poslovnih ciklusa zemalja predstavlja identifikacija poslovnih ciklusa zemalja, a ona prvenstveno ovisi o načinu definiranja poslovnih ciklusa.

Literatura o poslovnim ciklusima ističe dvije definicije poslovnih ciklusa:

- Klasični poslovni ciklusi;
- Devijacijski poslovni ciklusi (ciklusi rasta).

Između dvije navedene definicije poslovnih ciklusa postoji značajna konceptualna razlika.

Kod klasičnih poslovnih ciklusa, koje Burns i Mitchell (1946) definiraju kao apsolutne ekspanzije i kontrakcije agregatne ekonomske aktivnosti, točke preokreta definiraju se na način da se vrhovi identificiraju kao točke iza kojih slijedi apsolutni pad outputa, a dna kao točke nakon kojih slijedi apsolutni rast.

U slučaju devijacijskog poslovnog ciklusa točke preokreta definiraju se uzimajući u obzir devijaciju stope rasta outputa od odgovarajuće definiranog trenda stope rasta outputa. Zbog toga je potreban određeni filtar koji omogućava izdvajanje trenda i identifikaciju ciklusa (koji predstavlja devijaciju od tog trenda).

Datiranje klasičnih poslovnih ciklusa najčešće podrazumijeva korištenje tzv. “BB” algoritma razvijenog od strane Bry i Boschana (1971) koji replicira NBER-ovu (The National Bureau of Economic Research) proceduru za jednu vremensku seriju na mjesečnoj frekvenciji (npr. industrijska proizvodnja na mjesečnoj razini). Harding i Pagan (2002) razvijaju tzv. “BBQ” algoritam kojim se originalni BB algoritam prilagođava za korištenje vremenskih serija na kvartalnoj frekvenciji (npr. BDP).

Definicija točaka preokreta klasičnih ciklusa ponekad onemogućava prepoznavanje određenih uspona i padova u ekonomskoj aktivnosti kao poslovni ciklus, stoga je uobičajeno postaviti minimalna ograničenja trajanja kako pojedine faze poslovnog ciklusa, tako i poslovnog ciklusa u cijelosti. Primjerice Artis, Marcellino i Proietti (2003) postavljaju ograničenje trajanja pojedine

faze poslovnog ciklusa na minimalno dva kvartala, a na poslovni ciklus u cijelosti minimalno pet kvartala.

Artis, Chouliarakis i Harischandra (2011) ističu da su klasični poslovni ciklusi, u usporedbi s devijacijskim poslovnim ciklusima, rijetki u ekonomijama rasta i fokusiranje pozornosti na njih dovelo bi do malog broja opažanja, pogotovo u razdoblju nakon drugog svjetskog rata. Artis, Marcellino i Proietti (2003) identificiraju samo tri klasična poslovna ciklusa na području euro zemalja u razdoblju od 1970. do 2001. godine. Upravo je to jedan od glavnih razloga što se većina novijih istraživanja fokusira na devijacijske poslovne cikluse i metode filtriranja kojima se iz ukupnog outputa izdvajaju takvi ciklusi.

Devijacijski poslovni ciklus predstavlja razliku između realiziranog outputa (engl. actual output) i potencijalnog outputa (engl. potential output) i često se u literaturi zove jaz outputa (engl. output gap). Na slici 8. prikazani su devijacijski poslovni ciklusi i ključne veličine potrebne za njihovo razumijevanje.

Pozitivni jaz outputa stvara inflacijske pritiske, a negativni jaz outputa povezan je s nezaposlenošću. U tom kontekstu, jaz outputa predstavlja fundamentalnu determinantu kamatne stope središnje banke jer indicira inflacijski (deflacijski) pritisak u ekonomiji (Gachter i ostali, 2012). Razdvajanje trendovske i cikličke komponente u istraživanjima temelji se na pretpostavci da se ekonomskim politikama (fiskalnom i monetarnom) može djelovati samo na jaz outputa (putem potražnje), a potencijalni output isključivo je pod utjecajem čimbenika na strani ponude. Ovdje je važno napomenuti da dio literature ističe manjkavosti ovakvog pristupa, tj. kritizira korištenje koncepta jaza outputa, kao npr. Gavin (2012) ili Lubik i Slivinski (2010).

Slika 8. Devijacijski poslovni ciklusi

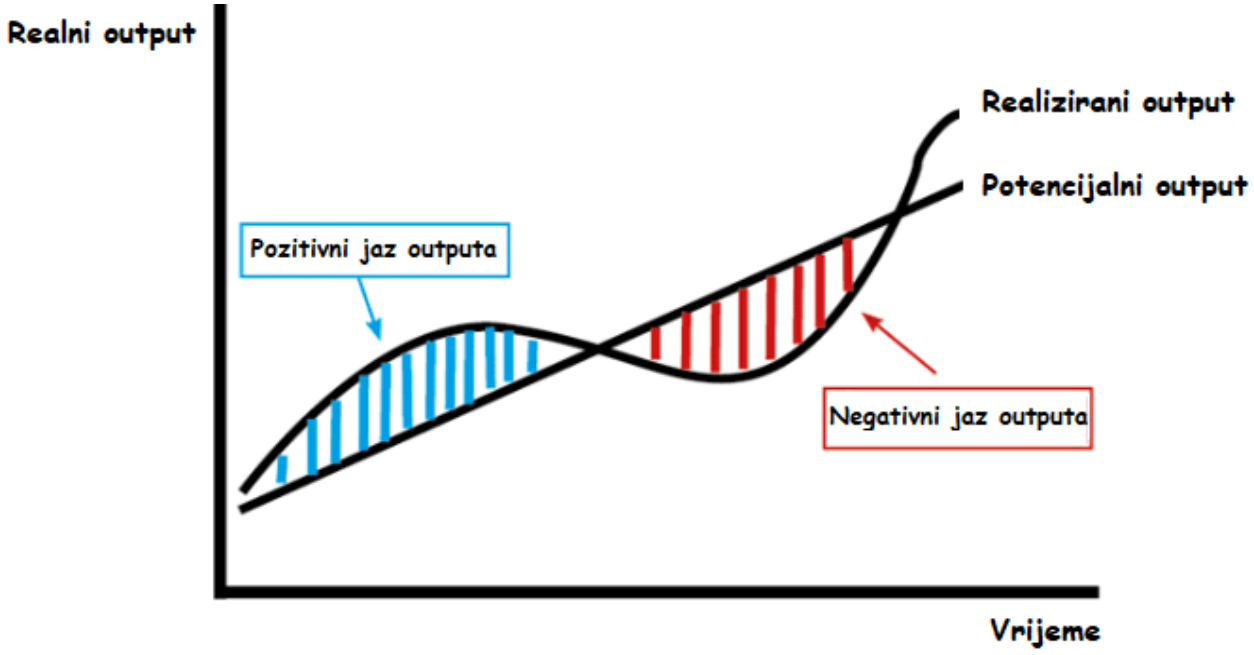

Izvor: Izrada autora

U ovoj disertaciji pod pojmom poslovnih ciklusa podrazumijevaju se devijacijski poslovni ciklusi, tj. jazovi output (engl. output gaps). Osim zbog prethodno navedene prednosti u odnosu na klasične poslovne cikluse, definiranjem poslovnih ciklusa na ovaj način može se napraviti bolja i obuhvatnija usporedba s dosadašnjim provedenim istraživanjima.

2.3.2. Procjena poslovnih ciklusa

Poslovne cikluse zemalja nije moguće izravno izmjeriti već ih je potrebno procijeniti. Poslovni ciklus aproksimira se cikličkom komponentom agregatne ekonomske aktivnosti. Literatura ističe tri vrste ekonomskih indikatora: navješćujući (engl. leading), zaostajući (engl. lagging) i koincidirajući (engl. coincident). Najčešće korišteni indikatori agregatne ekonomske aktivnosti u istraživanjima ovog tipa su:

a) Bruto domaći proizvod (BDP);
b) Indeks industrijske proizvodnje (IIP);
c) Stopa nezaposlenosti (UR).

a) Bruto domaći proizvod – Najveća prednost kod korištenja BDP-a je ta da BDP obuhvaća sve ekonomske sektore neke zemlje. Iz tog razloga predstavlja najkvalitetniji indikator agregatne ekonomske aktivnosti i omogućava najprecizniju procjenu poslovnih ciklusa. Kao glavni nedostatak ističe se njegova dostupnost na kvartalnoj razini što može biti ograničavajući čimbenik kad se radi o analizi kraćih vremenskih serija.

BDP kao indikator agregatne ekonomske aktivnosti u svojim istraživanjima koriste: Artis, Fidrmuc i Scharler (2008), Cerqueira i Martins (2009), Croux, Forni i Reichlin (2001), Darvas i Szapary (2006) i Imbs (2004).

b) Indeks industrijske proizvodnje - Glavna prednost korištenja indeksa industrijske proizvodnje kao indikatora agregatne ekonomske aktivnosti je njegova dostupnost za duže vremensko razdoblje (za većinu zemalja). Osim toga, za razliku od BDP-a koji je dostupan na kvartalnoj i godišnjoj razini, IIP je dostupan na mjesečnoj razini.
Dodatno, dio zemalja u stvarnosti ne mjeri BDP na kvartalnoj razini već se ti podaci dobiju pretvaranjem BDP-a na godišnjoj razini korištenjem određenih prihvatljivih indikatora. U takvim slučajevima preferira se korištenje indeksa industrijske proizvodnje. Dodatno, IIP ima visoku cikličku osjetljivost na poremećaje u makroekonomskim uvjetima što je svakako poželjna karakteristika za njegovo korištenje kao indikatora realne ekonomske aktivnosti.

Kao glavni nedostatak korištenja ovog indeksa ističe se slabija pokrivenost ekonomske aktivnosti koja je limitirana isključivo na proizvodni sektor. De Haan, Inklaar i Jong-a-Ping (2008) navode da proizvodna aktivnost predstavlja manje od 20 posto agregatnog outputa u eurozoni i stoga *a priori* ne predstavlja reprezentativnu mjeru ukupnog outputa, a osim toga proizvodni output mnogo je volatilniji od ukupnog outputa.

Zbog navedenih karakteristika u novijim istraživanjima koristi se kao alternativa BDP-u, najčešće prilikom analize robusnosti rezultata. IIP u svojim istraživanjima koriste Artis i Zhang (1999), Artis, Marcellino i Proietti (2003), Angeloni i Dedola (1999), Beine, Candelon i Hecq (2000), Massman i Mitchel (2004) i Camacho Perez-Quiros i Saiz (2006).

c) Stopa nezaposlenosti – Ranija istraživanja usklađenosti poslovnih ciklusa, uglavnom zbog nedostupnosti BDP-a ili navedene neprikladnosti IIP-a, za indikator agregatne ekonomske aktivnosti koriste stopu nezaposlenosti. Bellulo, Šonje i Vrbanc (2000) ističu da je stopa

nezaposlenosti kvalitetniji pokazatelj agregatne ekonomske aktivnosti od indeksa industrijske proizvodnje.

Stopu nezaposlenosti kao indikator agregatne ekonomske aktivnosti u svojim istraživanjima koriste: Boone i Maurel (1999), Bellulo, Šonje i Vrbanc (2000), Darvas, Rose i Szapary (2007) i Šonje i Vrbanc (2000).

Standardna procedura identifikacije devijacijskih poslovnih ciklusa zahtijeva izuzimanje trend komponente iz vremenskih serija. Literatura o poslovnim ciklusima ističe nekoliko metoda razdvajanja trend i cikličke komponente makroekonomskih varijabli. Najčešće korištene metode su:

- Filtar prvih diferencija;
- Hodrick-Prescott filtar;
- Baxter-King filtar;
- Christiano-Fitzgerald filtar;
- Trend faznog prosjeka;
- Rotemberg trend;
- Corbae i Ouliaris filtar.

Filtar prvih diferencija (eng. first order difference - FOD) ima nekoliko osnovnih pretpostavki: i) trend komponenta vremenske serije ima obilježja slučajnog hoda bez zanošenja (engl. drift); ii) ciklička komponenta je stacionarna; iii) ciklička i trend komponenta su nekorelirane; i iv) vremenska serija y_t ima jedinični korijen koji je u potpunosti posljedica trend komponente.

U skladu s osnovnim pretpostavkama vremenska serija y_t može se prikazati kao:

$$y_t = y_{t-1} + \varepsilon_t \quad ,$$

gdje je trend komponenta definirana kao $x_t = y_{t-1}$, a procijenjena ciklička komponenta c_t jednaka $\widehat{c_t} = y_t - y_{t-1}$.

Filtar prvih diferencija uklanja komponentu jediničnog korijena iz podataka zbog čega je poprilično popularan za korištenje. Baxter i King (1999) navode dva značajna nedostatka filtra prvih diferencija: (i) filtar nije simetričan pa zbog toga mijenja vremenski odnos između varijabli (postoji značajan fazni pomak); (ii) filtar uključuje dramatično ponovno ponderiranje (engl. re-

weighting) frekvencija. Ako je cilj filtriranja poslovnih ciklusa izoliranje fluktuacija u podacima koje se odvijaju između specifičnih periodičnosti, bez posebnog naglaska na neku određenu frekvenciju, filtar prvih diferencija je slab izbor (Baxter i King, 1999).

Hodrick-Prescott (HP) filtar je jedna od najpopularnijih metoda detrendiranja vremenskih serija. Pripada skupini visoko pojasnih filtara koji eliminira fluktuacije s frekvencijom većom od 32 kvartala i stavlja ih u trend. Razdvajanje vremenske serije na trend i cikličku komponentu svodi se na rješavanje problema minimizacije:

$$\min_{\tau}\left\{\sum_{t=1}^{T}(y_t-\tau_t)^2+\lambda\sum_{t=2}^{T-1}[(\tau_{t+1}-\tau_t)-(\tau_t-\tau_{t-1})]^2\right\} ,$$

gdje y predstavlja vremensku seriju, τ predstavlja trend, a λ multiplikator.

Rješenje problema minimizacije sastoji se od odabira takve trendovske serije $\{\tau\}_{t=1}^{T}$ koja minimizira gornju sumu kvadrata. Multiplikator λ predstavlja trošak uključivanja fluktuacija u trend, pri čemu veća vrijednost parametra jače izglađuje trendovsku komponentu.

Preporučene vrijednosti parametra izglađivanja λ su:

a) Za vremenske serije na mjesečnoj frekvenciji λ=14400;
b) Za vremenske serije na kvartalnoj frekvenciji λ=1600;
c) Za vremenske serije na godišnjoj frekvenciji λ=100.

Preporučene vrijednosti mogu se derivirati iz formule $100*f^2$ gdje f predstavlja frekvenciju vremenske serije (f = 1, 4 i 12 za godišnje, kvartalne i mjesečne podatke).

Akin (2012) ističe da se kritike korištenja HP filtra najčešće odnose na arbitraran izbor parametra izglađivanja λ. U slučaju primjene na serije stacionirane u diferencijama umjetno pojačava frekvencije poslovnog ciklusa i inducira podmetnuti ciklus. Također, u slučaju pojave trajnih šokova HP filtar generira pomake u trendu koje stvarno ne postoje čime izglađuje učinak iznenadnih strukturnih prekida u prethodnim i budućim razdobljima.

Baxter-King (BK) filtar pripada skupini pojasno propusnih filtara koji uklanja visoko frekventne fluktuacije kraće od 6 kvartala (koje mogu biti posljedica grešaka u mjerenju) i nisko frekventne fluktuacije duže od 32 kvartala koje reflektiraju dugoročnu komponentu rasta, zadržavajući samo cikličku komponentu vremenske serije.

Idealni oblik ovog filtra predstavljen je dvostranim beskonačnim pomičnim prosjekom, međutim kako on nije primjenjiv jer zahtijeva beskonačnu količinu podatka, Baxter i King (1999) predstavljaju njegovu aproksimaciju.

U vremenskoj domeni, utjecaj BK filtra na vremensku seriju y_t određen je konačnim pomičnim prosjekom $\tilde{y}_t = \sum_{j=-K}^{K} a_j L^j y_t$, gdje L označava lagirani operator ($L^n y_t = y_{t-n}$).

U frekvencijskoj domeni BK filtar je definiran svojom Fourierovom transformacijom α(ω).

Određivanje pondera a_j zahtijeva rješavanje problema minimizacije:

$$\min_{a_j} Q = \int_{-\pi}^{\pi} |\beta(\omega) - a(\omega)|^2 d\omega\,, \quad s.t. \alpha(0) = 0 \qquad ,$$

gdje $|\beta(\omega)|$ predstavlja idealnu korist filtra s odsječenim frekvencijama ω_1 i ω_2. Korist filtra mjeri promjenu amplitude ulaznih komponenti ako su transformirane samim filtrom. Korist idealnog pojasno propusnog filtra $|\beta(\omega)|$ poprima vrijednost 1 u frekvencijskom intervalu $[\omega_1, \omega_2]$, a 0 izvan navedenog intervala.

Rješavanje problema minimizacije vodi ka sljedećim rezultatima:

$$a_j = b_j + \theta; j = 0, \pm 1, \dots \pm K \qquad ;$$

$$b_j = \begin{cases} \dfrac{\omega_2 - \omega_1}{\pi} & ako\ je\ j = 0 \\ \dfrac{1}{\pi j}(\sin \omega_2 j - \sin \omega_1 j) & ako\ je\ j = \pm 1, \pm 2, \dots \end{cases} \qquad ;$$

$$\theta = \frac{-\sum_{j=-K}^{K} b_j}{2K+1} \qquad .$$

Oslanjajući se na svoje iskustvo s američkim poslovnim ciklusima Baxter i King (1999) predlažu sljedeći set parametara:

1) Za vremenske serije na kvartalnoj frekvenciji K=12, $\omega_1 = 2\pi \frac{1}{32}$, $\omega_2 = 2\pi \frac{1}{6}$ ili $\omega_2 = 2\pi \frac{1}{2}$;

2) Za vremenske serije na godišnjoj frekvenciji K=3, $\omega_1 = 2\pi \frac{1}{8}$, $\omega_2 = \pi$.

Woitek (1998) ističe da BK filtar ima poželjna svojstva koja ga čine u najmanju ruku razumnom alternativom široko korištenom HP filtru, posebno ako je kriterij izbora minimiziranje moguće štete kao što je opasnost od identificiranja lažne (engl. spurious) cikličke strukture.

Christiano-Fitzgerald (CF) filtar slučajnog hoda također pripada skupini pojasno propusnih filtara. Građen je na istim principima kao i BK filtar. S obzirom na to da konačne vremenske serije onemogućavaju korištenje idealnog pojasno propusnog filtra, Christiano i Fitzgerald (2003) predstavljaju njegovu optimalnu linearnu aproksimaciju koja se temelji na minimizaciji srednje kvadratne greške između idealnog filtra (y_t) i aproksimiranog filtra ($\hat{y}_t$) na uzorku x_t:

$$E\{(y_t - \hat{y}_t)^2 | x\}, x \equiv [x_1, \dots, x_T] \,.$$

Razlike između BK i CF filtra proizlaze upravo iz aproksimacije idealnog pojasno propusnog filtra koja se razlikuje u dvije pretpostavke. Prvo, BK filtar pretpostavlja da su varijable nezavisne i identično distribuirane, dok CF filtar pretpostavlja da je distribucija slučajni hod. Drugo, BK filtar pretpostavlja simetrične pondere, dok CF filtar izostavlja ovu pretpostavku.

CF filtar ima strmu funkciju frekvencijskog odziva na granicama filtra (nisku propusnost) i predstavlja asimetrični filtar koji u dugom roku konvergira idealnom filtru. Računa se prema formuli:

$$c_t = B_o y_t + B_1 y_{t+1} + \cdots + B_{T-1-t} y_{T-1} + \tilde{B}_{T-t} y_t + \tilde{B}_1 y_{t-1} + \cdots + B_{t-2} y_2 + \tilde{B}_{t-1 y_1} \quad ,$$

gdje je $B_j = \frac{\sin(jb) - \sin(ja)}{\pi j}, j \geq 1, i\ B_0 = \frac{b-a}{\pi}, a = \frac{2\pi}{p_u}, b = \frac{2\pi}{p_l}, \tilde{B}_k = -\frac{1}{2} B_0 - \sum_{j=1}^{k=1} B_j$.

Parametri p_u i p_j predstavljaju odrezanu duljinu ciklusa u mjesecima. Ciklusi dulji od p_l i kraći od p_u sačuvani su u cikličkoj komponenti c_t.

CF filtar je konstruiran za upotrebu na većoj klasi vremenskih serija nego BK filtar; a u aplikacijama u stvarnom vremenu (engl. real time applications) nadmašuje BK filtar. Osim toga, CF filtar daje bolje rezultate od BK filtra kod primjene na dužim vremenskim serijama (Nilsson i Gyomai, 2011).

Trend faznog prosjeka (eng. Phase Avreage Trend - PAT) konstruirali su Boschan i Ebanks (1978), a predstavlja metodu koja se sastoji od sljedećeg seta operacija:

- Prva procjena i ekstrapolacija dugoročnog trenda (putem 75-mjesečnog pomičnog prosjeka);
- Izračun devijacija od trenda pomičnog prosjeka;
- Korekcija ekstremnih vrijednosti;
- Identifikacija privremenih točaka zaokreta i određivanje cikličkih faza (ekspanzija i kontrakcija); putem Bry-Boschnan algoritma;
- Nova procjena dugoročnog trenda. Računanje prosjeka za svaku fazu, uglađivanje sekvence faznih prosjeka preko tri susjedne faze. Konačno, pozicioniranje uglađenih vrijednosti u središte njihovih odgovarajućih faza i linearno interpoliranje;
- Ekstrapolacija dugoročnog trenda na krajevima serije za oporavak izgubljenih razdoblja zbog korištenja centriranih pomičnih prosjeka;
- Izračun devijacija od PAT trenda.

Zarnowitz i Ozyildrim (2006) pokazuju da PAT metoda daje slične rezultate kao HP filtar i BK filtar, pri čemu ga smatraju ipak nešto superiornijim u odnosu na njih.

Nillson i Gyoami (2011) ističu da je PAT metoda nedovoljno transparentna i to zbog dva razloga: (i) algoritam kojim se vrši procjena ciklusa nije dostupan u glavnim ekonometrijskim programima; (ii) zbog ručnog unošenja točaka zaokreta podložan je velikoj dozi subjektivnosti u procjeni.

Rotemberg trend je heuristička metoda dekompozicije vremenskih serija. Predstavlja je Rotemberg (1999).
Neka y_t predstavlja vremensku seriju koja se satoji od trend komponente g_t i cikličke komponente c_t ($y_t = g_t + c_t$). Konstrukcija trenda svodi se na minimiziranje:

$$\sum_{t=1+k}^{T} c_t * c_{t-k} + \lambda \sum_{t=2}^{T-1} [(g_t - g_{t-1}) - (g_{t-1} - g_{t-2})]^2,$$

gdje je parametar λ postavljen na najnižu moguću vrijednost koja osigurava da je:

$$\sum_{t=k+v}^{T-k-v} c_t * [(g_{t+v} - g_t) - (g_t - g_{t-v})] = 0.$$

Procedura zahtijeva uvođenje dva cjelobrojna parametra, k i v. Parametar k osigurava da procijenjeni trend minimizira kovarijancu dvije vrijednosti cikličke komponente c_ti c_{t+k}.

Parametar v osigurava da su trend i ciklička komponenta, g_t i c_t, ortogonalne preko horizonta od v razdoblja.

S velikim k dolazi do identifikacije trenda koji je poprilično izglađen i ne baš pretjerano osjetljiv na ciklička kretanja vremenske serije i izbor v. Rotemberg (1999) preporuča postavljanje k na 16 kvartala što temelji na prosječnoj dužini trajanja NBER poslovnih ciklusa u SAD-u, a v na pet kvartala.

Corbae i Ouliaris (FD) filtar predstavlja aproksimaciju tzv. idealnog pojasno propusnog filtra. Predstavljaju ga Corbae i Ouliaris (2006). FD filtar izolira komponentu vremenske serije unutar definiranog raspona. U analizi poslovnih ciklusa to su ciklusi od 1,25 godina (5 kvartala) do 8 godina (32 kvartala). Prednost FD filtra u odnosu na druge filtre je mogućnost korištenja kod nestacionarnih serija bez prethodnog testiranja oblika nestacionarnosti, za razliku od npr. Christiano-Fitzgeraldovog ili Baxter-Kingovog filtra.

Važno je napomenuti da većina navedenih metoda detrendiranja često implicitno pretpostavljaju postojanje isključivo trend i cikličke komponente u vremenskim serijama. Što znači da zahtijevaju da su podaci sezonski prilagođeni ili da su sezonska i ciklička komponenta spojene i da neregularne (visoko frekventne) fluktuacije imaju maleni utjecaj. U slučaju da u vremenskim serijama ipak postoji izražen sezonski utjecaj iz istih je potrebno izdvojiti sezonsku komponentu. Najčešće korištene metode desezoniranja su: X-12-ARIMA, TREAMO/SEATS ili DAINTES.

2.3.3. Mjere usklađenosti poslovnih ciklusa

Nakon što su procijenjeni poslovni ciklusi zemalja može se pristupiti mjerenju njihove međusobne usklađenosti. Literatura ističe nekoliko različitih mjera usklađenosti poslovnih ciklusa između zemalja.

Najčešće korištene mjere usklađenosti poslovnih ciklusa su:

- Pearsonov koeficijent linearne korelacije;
- Dinamička korelacija;
- Fazno prilagođena korelacija;
- Cerqueira-Martins kros korelacijski indeks;

- Indeks podudarnosti;
- Indeks difuzije.

Pearsonov koeficijent linearne korelacije je najpoznatija mjera korelacije između slučajnih varijabli:

$$r = \frac{\sum_{i=1}^{n}(X_i-\bar{X})*(Y_i-\bar{Y})}{\sqrt{\sum_{i=1}^{n}(X_i-\bar{X})^2*\sum_{i=1}^{n}(Y_i-\bar{Y})^2}} \quad \text{ili} \quad \mathrm{r} = \frac{\sum_{i=1}^{n}X_iY_i-n*\bar{X}*\bar{Y}}{n*\sigma_x*\sigma_y} \quad ,$$

gdje su σ_x i σ_y jednostavne standardne devijacije promatranih varijabli:

$$\sigma_x = \sqrt{\frac{\sum_{i=1}^{n}{x_i}^2}{n} - \bar{X}^2} \quad \text{i } \sigma_y = \sqrt{\frac{\sum_{i=1}^{n}{y_i}^2}{n} - \bar{Y}^2} \quad .$$

Vrijednost koeficijenta linearne korelacije kreće se u intervalu [-1,1], a njegova veličina i predznak ukazuju na intenzitet i smjer linearne korelacije između promatranih varijabli pri čemu:

r = -1 predstavlja funkcionalnu negativnu korelaciju, a r = 1 funkcionalnu pozitivnu korelaciju;
-1 < r ≤ -0,8 jaku negativnu korelaciju, a 0,8 ≤ r < 1 jaku pozitivnu korelaciju;
-0,8 < r ≤ -0,5 srednje jaku negativnu korelaciju, a 0,5 ≤ r < 0,8 srednje jaku pozitivnu korelaciju;
-0,5 < r ≤ 0 slabu negativnu korelaciju, a 0 ≤ r < 0,5 slabu pozitivnu korelaciju;
r = 0 nema korelacije.

S obzirom na to da se koeficijenti Pearsonove korelacije nalaze u navedenom intervalu, da bi se postigla normalnost distribucije uobičajena praksa je primjena Fisherove z-transformacije korelacijskih koeficijenata:

$$z = \frac{1}{2} ln \frac{1+\rho}{1-\rho} \quad .$$

Dinamička korelacija definirana je u frekvencijskoj domeni i prikladna je za procese koji su kostacionarni. Predstavili su je Croux, Forni i Reichlin (2001). Autori pokazuju da je, za vremenske serije s beskonačnim brojem opažanja, dinamička korelacija između dvije serije u frekvencijskom pojasu jednaka regularnoj korelaciji između dvije pojasno propuštene (engl. band-passed) serije. Za konačne vremenske serije ova jednakost općenito ne stoji jer su i pojasno propusni filtar i dinamička korelacija procijenjeni nesavršeno.

Promotrimo dva stohastička i stacionarna procesa x i y. Neka je s(ω) matrica spektralne gustoće matrice kovarijanci na frekvenciji $-\pi \leq \omega \leq \pi$. Spektar x i y označen je sa $s_x(\omega)$ i $s_y(\omega)$, a kros spektar između x i y označen je sa $s_{xy}(\omega)$. Croux, Forni i Reichlin (2001) predstavljaju indeks zajedničkog kretanja koji nazivaju koherencija i definiraju je kao:

$$h_{xy}(\omega) = \frac{s_{xy}(\omega)}{\sqrt{s_x(\omega)s_y(\omega)}} \quad .$$

Koherencija mjeri korelaciju između kompleksne reprezentacije x_t i y_t na frekvenciji ω.

Budući da kros spektar sadrži imaginarni dio indeks nije realan. Da bi se dobila prikladnija mjera usklađenosti Tripier (2002) predlaže korištenje kvadrirane koherencije $h_{xy}^2(\omega)$ koja se definira kao:

$$h_{xy}^2(\omega) = \frac{\left|s_{xy}(\omega)\right|^2}{s_x(\omega)s_y(\omega)} \quad .$$

Kvadrirana koherencija interpretira se kao doprinos frekvencije ω kvadriranom koeficijentu korelacije i invarijantna je u odnosu na pomak u vremenskom procesu: $h_{xy}^2(\omega)$ jednak je $h_{zy}^2(\omega)$ gdje je $z_t = x_{t+k}$, a k predstavlja pomak u vremenskom procesu. Da bi izbjegli navedeno ograničenje Croux, Forni i Reichlin (2001) predlažu izdvajanje realnog dijela koherencije i nazivaju ga dinamička korelacija koju definiraju kao:

$$\rho_{xy}(\omega) = \frac{c_{xy}(\omega)}{\sqrt{s_x(\omega)s_y(\omega)}} \quad ,$$

pri čemu je $0 \leq \omega \leq \pi$, a $c_{xy}(\omega)$ kospektar između x i y ($c_{xy}(\omega)$=real($s_{xy}(\omega)$).

Za razliku od koherencije, dinamička korelacija mjeri korelaciju između realnih valova x_t i y_t, a ne kompleksnih valova. Croux, Forni i Reichlin (2001) ističu da dinamička korelacija poprima vrijednosti [-1,1] i ovisna je o pomaku u vremenskom procesu što joj daje prednost u njezinom korištenju kod mjerenja usklađenosti poslovnih ciklusa između zemalja.

De Haan, Inklaar i Jong-a-Pin (2008) ističu da ova mjera pruža korisnu sumarnu statistiku o stupnju usklađenosti unutar grupe zemalja izbjegavajući pri problem izbora bazne zemlje.

Fazno prilagođenu korelaciju predstavili su Koopman i Azevedo (2003). Navedeni autori modeliraju multivarijatne stohastičke ciklične procese eksplicitno putem trigonometrijskih identiteta s vremenski varirajućim amplitudama i fazama. Takve stohastičke ciklične komponente mogu biti ugrađene u multivarijatne modele neopaženih komponenti. Stohastički ciklični vektor Ψ_t modeliraju na sljedeći način:

$$\begin{pmatrix} \Psi_{t+1} \\ \Psi_{t+1}^{+} \end{pmatrix} = \Phi f(x) = \begin{bmatrix} \cos(\lambda) I_N & \sin(\lambda) I_N \\ -\sin(\lambda) I_N & \cos(\lambda) I_N \end{bmatrix} \begin{pmatrix} \Psi_t \\ \Psi_t^{+} \end{pmatrix} + \begin{pmatrix} \kappa_t \\ \kappa_t^{+} \end{pmatrix} \quad , \quad t = 1, \dots, n \quad ,$$

gdje I_k predstavlja k x k matricu identiteta. N x 1 vektor Ψ_t sastoji se od sličnih ciklusa sa zajedničkom frekvencijom λ i zajedničkim autoregresivnim koeficijentom $|\Phi| < 1$, a N x 1 vektor Ψ_t^{+} je konstruirana varijabla. N x 1 vektori poremećaja κ_t i κ_t^{+} su serijski i međusobno nekorelirani i normalno distribuirani s nultom očekivanom vrijednošću i matricom varijanci:

$$Var \begin{pmatrix} \kappa_t \\ \kappa_t^{+} \end{pmatrix} = \begin{bmatrix} \Sigma_k & 0 \\ 0 & \Sigma_k \end{bmatrix} \quad ,$$

što implicira da κ_ti κ_t^{+}imaju zajedničku matricu varijanci Σ_k. Ovakva specifikacija generira višestruke stacionarne ciklične procese s periodom $f=2\pi/\lambda$. Individualni ciklusi u Ψ_t imaju slična svojstva zbog zajedničkog Φ i λ. Autokovarijancijska funkcija za Ψ_t definirana je na sljedeći način: $\Gamma(\tau) = (1-\Phi^2)^{-1}\Phi^{\tau}\cos(\tau\lambda)\Sigma_k$, (τ=0,1,2,…), iz čega slijedi da je matrica varijanci zadana u obliku: $\Gamma(0) = (1-\Phi^2)^{-1}\Sigma_k$. Nametanje iste faze ciklusa i faktora izglađivanja je prihvatljivo jer reflektira sličnu dinamiku flukutuacija poslovnih ciklusa između makroekonomskih vremenskih serija iste ekonomije ili između različitih ekonomija.

Vektorska varijabla y, koja je subjekt cikličnog procesa vremenske serije i moguće izmjerena sa šumom, može se modelirati kao: $y_t = \mu + \Psi_t + \varepsilon_t$, pri čemu je $\varepsilon_t \sim NID(0, \Sigma_\varepsilon), t = 1, \dots, n,$ gdje je y_t N x 1 vektor vremenske serije. N x 1 vektor konstanti μ je nepoznat, a N x 1 neregularni vektor ε_t s nultom očekivanom vrijednošću i N x N matricom varijanci Σ_ε nekoreliran je s poremećajima povezanim s cikličkim vektorom Ψ_t kontinuirano kroz vremensko razdoblje i između različitih vremenskih razdoblja. Nepoznati parametri u navedenom modelu su matrice varijanci Σ_ε i Σ_k zajedno s autoregresivnim koeficijentom Φ i cikličnom frekvencijom λ koji se mogu procijeniti korištenjem metode maksimalne vjerodostojnosti.

Za potrebe procjene Koopman i Azevedo (2003) transformiraju parametre u vektor θ tako da proces maksimalne vjerodostojnosti može teći bez ograničenja. Pretpostavljaju da je iregularna

matrica varijanci dijagonalna i specificirana na način: $\Sigma_\varepsilon = \mathrm{diag}\{\exp(2\theta_{\varepsilon,1}), \dots, \exp(2\theta_{\varepsilon,N})\}$, gdje je $2\theta_{\varepsilon,1}$ logaritam standardne devijacije i-tog elementa iregularnog vektora ε_t za *i=1,…,N*.

Matrica varijanci cikličnih poremećaja definirana je kao Σ_k=CRC, gdje je C dijagonalna matrica standardnih devijacija, a matrica R sastoji se od koeficijenata korelacije:

$$C = \mathrm{diag}\{\exp(\theta_{\kappa,1}), \dots, \exp(\theta_{\kappa,N})\}, \qquad R = \begin{bmatrix} 1 & \rho_{\kappa,2,1} & \cdots & \rho_{\kappa,N,1} \\ \rho_{\kappa,2,1} & 1 & \cdots & \rho_{\kappa,N,2} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{\kappa,N,1} & \rho_{\kappa,N,2} & \dots & 1 \end{bmatrix},$$

gdje je $\theta_{\kappa,i}$ logaritam standardne devijacije. Matrica R je pozitivno semidefinitna. U bivarijatnom slučaju N=2 dovoljan uvjet je $-1 \leq \rho_{\kappa,2,1} \leq 1$ što se određuje kao:

$$\rho_{\kappa,2,1} = \frac{\theta_{\kappa,2,1}}{\sqrt{1+\theta_{\kappa,2,1}^2}}$$, tako da je $\rho_{\kappa,2,1} \to \pm 1$, a $\theta_{\kappa,2,1} \to \pm\infty$.

Kad su korelacije procijenjene na nulu (ili signifikantno blizu nuli) individualni ciklusi Ψ_t neovisni su jedan o drugome. U suprotnom slučaju, kada su korelacije signifikantno blizu jedan (± 1) individualni ciklusi kreću se zajedno i varijanca Σ_k ima niži rank.

Cerqueira i Martins (2009) predstavljaju alternativnu mjeru kros korelacije poslovnih ciklusa između dviju zemalja:

$$r_{ij,t} = 1 - \frac{1}{2}\left(\frac{d_{j,t} - \overline{d}_j}{\sqrt{\frac{1}{T}\sum_{t=1}^{T}(d_{j,t} - \overline{d}_j)^2}} - \frac{d_{i,t} - \overline{d}_i}{\sqrt{\frac{1}{T}\sum_{t=1}^{T}(d_{i,t} - \overline{d}_i)^2}}\right)^2 \qquad ,$$

gdje $r_{ij,t}$ predstavlja kros korelaciju između zemalja i i j u vremenu t, $d_{i,t}$ predstavlja stopu rasta BDP-a zemlje i između t i t-1, a $\overline{d}_i$ prosjek stopa rasta BDP-a od t=1 do T (zadnja godina u cijelom uzorku).

Gornja granica $r_{ij,t}$ je 1, a donja granica može poprimiti velike negativne vrijednosti koje mogu biti manje od -1. Cerqueira i Martins (2009) ističu da korištenje ovog indeksa ima nekoliko prednosti: 1) Razlikuje privremene negativne korelacije koje nastaju zbog negativnih šokova u jednoj godini; 2) Nije potrebno odrediti vremenski raspon i 3) Nema gubitka opažanja.

Da bi nadvladali asimetričnost indeksa, koju smatraju tehničkim nedostatkom, Artis i Okubo (2011) koriste proširenu Fisherovu transformaciju:

$$\rho_{ij,t} = \frac{1}{2}\log\left(\frac{1}{1 - r_{ijt}}\right) \quad ,$$

gdje r_{ijt} predstavlja Cerqueira-Martins (2009) kros korelaciju.

Navedenom transformacijom indeks postaje simetričan, tj. njegove granice nalaze se u intervalu od -∞ do +∞.

Indeks podudarnosti (engl. concordance index) predstavili su Harding i Pagan (2002), a predstavlja neparametrijsku mjeru usklađenosti koja koristi binarni indikator recesija i ekspanzija.

Indeks podudarnosti pokazuje udio vremena u kojem se poslovni ciklusi nalaze u istoj fazi:

$$\hat{I} = \frac{1}{T}\left\{\sum_{t=1}^{T} S_{xt}S_{yt} + \sum_{t=1}^{T}(1 - S_{xt})(1 - S_{yt})\right\} \quad ,$$

gdje S_t predstavlja specifični ciklus - varijablu koja poprima vrijednost 0 u fazi ekspanzije, a vrijednost 1 u fazi recesije. Svojstva varijable ovise o načinu na koji se definira poslovni ciklus. Varijabla T predstavlja veličinu uzorka. Nakon deriviranja dobije se sljedeća formula:

$$\hat{I} = 1 + 2\hat{\rho}_S(\hat{\mu}_{S_x}(1 - \hat{\mu}_{S_x}))^{\frac{1}{2}}(\hat{\mu}_{S_y}(1 - \hat{\mu}_{S_y}))^{\frac{1}{2}} + 2\hat{\mu}_{S_x}\hat{\mu}_{S_y} - \hat{\mu}_{S_x} - \hat{\mu}_{S_y} \quad ,$$

gdje $\hat{\rho}_S$ predstavlja koeficijent korelacije između S_{xt} i S_{yt}. Kad je $S_{xt} = S_{yt}$ indeks poprima vrijednost 1, a kad je $S_{xt} = (1 - S_{yt})$ onda poprima vrijednost 0.

Mink, Jacobs i De Haan (2008) primjenjuju indeks podudarnosti kao mjeru usklađenosti poslovnih ciklusa između n zemalja koristeći za definiciju poslovnih ciklusa devijacijske poslovne cikluse:

$$\varphi(t) = \frac{1}{n}\sum_{i=1}^{n}\frac{g_i(t)g_r(t)}{|g_i(t)g_r(t)|} \quad ,$$

gdje $g_i(t)$ predstavlja output gap zemlje i u vremenu t, a $g_r(t)$ output gap regije u vremenu t.

Vrijednost indeksa poprima vrijednost 1 kad su $g_i(t)$ i $g_r(t)$ istog predznaka, a vrijednost -1 kad su različitog predznaka.

Slično tome, Mink, Jacobs i De Haan (2008) usklađenost poslovnih ciklusa između zemlje i referentnog ciklusa u razdoblju t definiraju:

$$\varphi_{ir}(t) = \frac{g_i(t)g_r(t)}{|g_i(t)g_r(t)|} \qquad .$$

Uprosječeno kroz vremensko razdoblje i transformirano na skalu [0,1] mjera pokazuje udio vremena u kojem jaz outputa zemlje *i* ima isti predznak kao i jaz outputa referentnog ciklusa. Lako ju je interpretirati, a također pruža bolju kvantifikaciju usklađenosti ciklusa nego korelacija jaza outputa.

De Haan, Inklaar i Jong-a-Pin (2008) ističu da je indeks podudarnosti fleksibilniji od koeficijenta korelacije jer dopušta primjenu bilo koje metode za razdvajanje između recesija i ekspanzija. Kao glavni nedostatak navode da korištenje binarnog indikatora odbacuje potencijalno korisne informacije. Zaključuju da indeks podudarnosti može predstavljati komplement mjerama korelacije između detrendiranih serija, kao i korisnu mjeru za analizu klasičnih poslovnih ciklusa.

Indeks difuzije poslovnih ciklusa mjeri udio ekonomskih vremenskih serija u određenoj fazi, npr. fazi recesije. Njegova svrha je na kontinuiranoj skali [0,1] prikazati koliko su raširena kretanja poslovnih ciklusa kroz ekonomiju.

Artis, Marcellino i Proietti (2003) ističu da postoje dva načina konstrukcije indeksa difuzije. Prvi način zbraja svaku individualnu vremensku seriju nakon čega računa kros-sekcijski prosjek:

$$D_t = \frac{1}{N}\sum_{i=1}^{N} S_{it} \quad , \qquad t = 1, \dots, T \quad ,$$

pri čemu S_{it} poprima vrijednost 1 u recesijama (a u ostalim slučajevima 0), a N predstavlja kros-sekcijsku dimenziju.

Vremenske serije mogu se i ponderirati prema njihovoj ekonomskoj relevantnosti i/ili dokazanoj efikasnosti u signaliziranju recesijskih događaja. Ako se formira sistem pondera onda vrijedi:

$$D_t = \sum_{i=1}^{N} w_{it}\, S_{it} \quad , \text{t=1,…,T} \quad , \ \sum_i w_{it} = 1 \quad .$$

Agregatni indeks D_t predstavlja konačnu kombinaciju Markovljevih procesa dviju zemalja, pri čemu su kombinacije vjerojatnosti definirane s ponderom w_{it}. Uz pretpostavku da su individualne vremenske serije komponente agregata $y_t = \sum_i w_i y_{it}$ i da za recesije vrijedi pravilo izračuna da je $S_t = I(\Delta y_t < 0)$, gdje je I(·) indikator funkcije onda vrijedi:

$$E(S_t) = P(\sum_i w_i \Delta y_{it} < 0) > E(D_t) = \sum_{i=1}^{N} w_{it} E(S_{it}) \quad .$$

Indeks difuzije ne mjeri vjerojatnost recesije u agregatnoj seriji, nego mjeri proporciju agregata koja se nalazi u fazi recesije.

Drugi način konstrukcije indeksa difuzije koristi algoritam datiranja faza ciklusa koristeći BBQ pravilo Hardinga i Pagana (2002) prema kojem Artis, Marcellino i Proietti (2003) definiraju sekvencu završetka ekspanzije (engl. expansion terminating sequence, ETS) i sekvencu završetka recesije (engl. recession terminating sequence, RTS):

$$ETS_t = \{(\Delta y_{t+1} < 0) \cap (\Delta_2 y_{t+2} < 0)\} \quad ,$$
$$RTS_t = \{(\Delta y_{t+1} > 0) \cap (\Delta_2 y_{t+2} > 0)\} \quad .$$

ETS_t definira vrh, tj. točku kojom završava faza ekspanzije, a RTS_t definira dno, tj. točku u kojoj završava faza recesije. Zajednička distribucija sekvenci $\{ETS_t,\ RTS_t, t = 1, \dots, T\}$ ovisi o stohastičkom procesu koji generira dostupnu seriju i koji je često analitički tvrdoglav (engl. intractable) zbog prisutnosti serijske korelacije i međusobne neisključivosti terminirajućih sekvenci.

Prethodno navedeno definiranje terminirajućih sekvenci odnosi se na klasične poslovne cikluse. U slučaju da se radi o devijacijskim poslovnim ciklusima potrebno je spriječiti lociranje vrha ispod razine trenda (jer po definiciji devijacijskih poslovnih ciklusa ekspanzija mora imati output iznad trenda). Stoga Artis, Marcellino i Proietti (2003) za devijacijske poslovne cikluse s nultom očekivanom vrijednosti (engl. zero mean deviation cycle) mijenjaju BBQ pravilo (nazivaju ga BBQDC) redefinirajući terminirajuće sekvence:

$$ETS_t = \{(\Delta y_t > 0) \cap (\Delta y_{t+1} < 0) \cap (\Delta_2 y_{t+2} < 0)\} \quad ,$$
$$RTS_t = \{(\Delta y_t < 0) \cap (\Delta y_{t+1} > 0) \cap (\Delta_2 y_{t+2} > 0)\} \quad .$$

Vjerojatnost prijelaza računa se korištenjem vjerojatnosti pridruženoj terminirajućim sekvencama ekspanzije i recesije na sljedeći način:

$$\mathcal{P}_t^{ETS} = \sum_{i=1}^{N} w_{it} I(ETS_{it}) \quad , \qquad \mathcal{P}_t^{RTS} = \sum_{i=1}^{N} w_{it} I(RTS_{it}) \quad .$$

Sekvenca terminacije ekspanzije definira potencijalnu točku za vrh, a ekspanzija završava u vremenu t kad su uvjeti $(\Delta y_{t+1} < 0)$ i $(\Delta_2 y_{t+2} < 0)$ zadovoljeni. S druge strane, sekvenca terminacije recesije definira potencijalnu točku za dno, a ekspanzija završava u vremenu t kad su zadovoljeni uvjeti $(\Delta y_{t+1} > 0)$ i $(\Delta_2 y_{t+2} > 0)$. Uzimajući u obzir navedeno pravilo, tranzicijske vjerojatnosti ovise o sumi pondera vremenskih serija koje se nalaze u te dvije terminacijske sekvence. Opet, osnovna pretpostavka je da je agregatni ETS_t konačna kombinacija kros-sekcijskog ETS_{it} i da algoritam datiranja ima vjerojatnosti koje se interpretiraju kao $P(D_t) = 1$, a ne kao $P(S_t) = 1$.

De Haan, Inklaar i Jong-a-Pin (2008) ističu da indeks difuzije može omogućiti kvalitetan uvid u zajedničko kretanje agregata u svakoj vremenskoj točki.

2.3.4. Pregled dosadašnjih istraživanja usklađenosti poslovnih ciklusa

U dosadašnjoj literaturi ističe se mnoštvo radova koji analiziraju usklađenost poslovnih ciklusa zemalja, što je i očekivano s obzirom na važnost koncepta usklađenosti poslovnih ciklusa kao meta kriterija monetarnog integriranja.

Fidrumc i Korhonen (2006) daju pregled istraživanja usklađenosti poslovnih ciklusa zemalja srednje i istočne Europe (CEEC) u razdoblju od 1998. do 2005. godine, a Njegić, Živkov i Damnjanović (2017) pregled istraživanja CEEC zemalja u razdoblju od 2004. do 2016. godine. Kovačič i Vilotić (2017) daju pregled istraživanja nakon 2010. godine u kojima se analizira usklađenost poslovnih ciklusa zemalja koje su nedavno pristupile u EU, koje su pristupile nakon 2004. i onih zemalja koje su u procesu pristupanja u EU. U nastavku je dan prikaz istraživanja usklađenosti poslovnih ciklusa koja u svojoj analizi uključuju Hrvatsku.

Šonje i Vrbanc (2000) analiziraju usklađenost poslovnih ciklusa Hrvatske, Mađarske i Češke prema Njemačkoj u razdoblju od 1992. do 1999. godine. Za indikator poslovnog ciklusa koriste desezoniranu stopu nezaposlenosti, pri čemu cikličku komponentu izoliraju putem Hodrick-Prescottovog filtra. Dodatno, njemačke šokove identificirali su primjenom ARMA(p,q) modeliranja. Rezultati njihovog istraživanja potvrđuju da poslovni ciklusi Hrvatske, Mađarske i

Češke imaju usku povezanost s cikličkim kretanjima nezaposlenosti u Njemačkoj. Osim toga, veliki postotak fluktuacija poslovnog ciklusa navedenih tranzicijskih zemalja objašnjen je njemačkim šokom, što upućuje na zaključak da zemlje slično reagiraju i tvore homogenu skupinu zemalja.

Slično Šonji i Vrbancu (2000), Bellulo, Šonje i Vrbanc (2000) analiziraju usklađenost poslovnih ciklusa na proširenom uzorku tranzicijskih zemalja. Naime, autori mjere povezanost poslovnih ciklusa Hrvatske, Bugarske, Češke, Mađarske, Poljske, Rumunjske, Slovačke, Slovenije i Austrije sa šokovima u njemačkom poslovnom ciklusu i agregiranom ciklusu Europske Unije (EU-15) u razdoblju od siječnja 1992. do kolovoza 1999. godine. Poslovne cikluse zemalja mjere desezoniranom cikličkom komponentom nezaposlenosti, a šokove identificiraju primjenom ARIMA(p,d,q) modeliranja. Autori zaključuju da postoji jaka linearna veza između njemačkog i europskog šoka nezaposlenosti i cikličke nezaposlenosti analiziranih tranzicijskih zemalja, što znači da bi korist od pridruživanja eurozoni za te zemlje bila visoka.

Furceri i Karras (2006) analiziraju usklađenost poslovnih ciklusa 30 europskih zemalja (12 EMU zemalja, tri stare EU zemlje koje nisu prihvatile euro, deset novih zemalja i pet potencijalnih zemalja članica) s agregiranom eurozonom u razdoblju od 1980. do 2003. godine koristeći Spearmanov koeficijent korelacije ranga cikličke komponente realnog godišnje BDP-a. Cikličku komponentu izoliraju putem tri različite metode: (i) filtra prvih diferencija; (ii) Hodrick-Prescott filtra (parametar uglađivanja 6,25); i (iii) Baxter-King filtra. Rezultati njihovog istraživanja pokazuju da Slovenija, Cipar i Mađarska imaju visoko usklađene poslovne cikluse s eurozonom, Latvija i Estonija imaju niski stupanj usklađenosti, dok Rumunjska, Turska i Hrvatska imaju negativne korelacije.

Obradović i Mihajlović (2013) analiziraju usklađenost poslovnog ciklusa Srbije, Bugarske, Rumunjske, Hrvatske, Mađarske i Slovenije s poslovnim ciklusom eurozone (EA-15) u razdoblju od 1995. do 2010. godine. Poslovni ciklus aproksimiraju realnim BDP-om, cikličku komponentu izoliraju korištenjem dvostrukog Hodrick-Prescott filtra i Baxter-King filtra, a usklađenost mjere Pearsonovim koeficijentom korelacije. Rezultati njihovog istraživanja značajno se razlikuju ovisno o korištenom filtru. Naime, kod HP filtra postoji izravna snažna veza između poslovnog ciklusa eurozone i Slovenije, Hrvatske, Rumunjske te Bugarske, dok kod BK filtra takva veza postoji isključivo kod Hrvatske i Rumunjske. Dodatno, usporedbom korelacijskih koeficijenata u

tri podrazdoblja (2001Q1-2005Q4; 2003Q1-2007Q4; 2005Q1-2009Q4) dokazuju da usklađenost poslovnog ciklusa Hrvatske s eurozonom drastično raste u drugom promatranom podrazdoblju (u prvom podrazdoblju koeficijent korelacije iznosi niskih 0,290), dok se u trećem razdoblju zanemarivo smanjuje (koeficijent korelacije opada s 0,985 na 0,978).

Gouveia (2014) analizira usklađenost poslovnih ciklusa između osam zemalja jugoistočne Europe (Slovenija, Makedonija, Srbija, Hrvatska, Rumunjska, Bugarska, Grčka, Turska.) i agregirane eurozone (EMU-17) u razdoblju od 2001. do 2011. godine. Za indikator poslovnog ciklusa koristi sezonski prilagođeni kvartalni realni BDP, cikličku komponentu izolira korištenjem Hodrick-Prescottovog i Baxter-Kingovog filtra, a usklađenost Spearmanovim koeficijentom korelacije ranga i Harding-Paganovim indeksom podudarnosti. U svrhu analize dinamike usklađenosti poslovnih ciklusa koristi pomični vremenski okvir od 16 opažanja. Dodatno, izračunava indekse u fiksnim intervalima od četiri godine (2000-2003, 2004-2007, 2008-2011) u skladu s važnim događajima za promatrane zemlje u kontekstu europske integracije. U cjelokupnom razdoblju sve promatrane zemlje (osim Grčke) imaju pozitivnu, statistički značajnu korelaciju s eurozonom. Slovenija i Makedonija imaju snažnu poveznicu s ciklusom eurozone, dok ostale zemlje imaju skromnu povezanost. Koeficijent korelacije poslovnog ciklusa Hrvatske s ciklusom eurozone iznosi 0,54. Analiza usklađenosti poslovnih ciklusa u podrazdobljima pokazuje da su Hrvatska i Grčka jedine od promatranih zemalja u razdoblju od 2000. do 2003. godine ostvarile negativne, statistički značajne korelacije (Hrvatska (-0,53), Grčka (-0,91)) uz vrlo niske indekse podudarnosti (Hrvatska (0,00), Grčka (0,06)). U drugom podrazdoblju (2004-2007) sve zemlje (osim Srbije) imaju relativno visoku usklađenost poslovnih ciklusa s eurozonom, pri čemu Slovenija ostvaruje gotovo savršenu usklađenost (koeficijent korelacije (0,98); indeks podudarnosti (0,94)). U trećem razdoblju (2008-2011) općenito dolazi do pada usklađenosti poslovnih ciklusa s eurozonom u odnosu na prethodno promatrano razdoblje. Autorica zaključuje da Hrvatska, Srbija, Rumunjska i Bugarska ostvaruju skromnu usklađenost poslovnih ciklusa s eurozonom i da trebaju daljnji napredak po pitanju promatranog kriterija ako žele prihvatiti euro bez velikih troškova stabilizacije.

Hildebrandt i Moder (2015) analiziraju dinamiku i usklađenost poslovnih ciklusa između sedam zemalja Zapadnog Balkana (Albanija, Bosna i Hercegovina, Crna Gora, Hrvatska, Kosovo, Makedonija i Srbija) i Europske Unije (EU-25) u razdoblju od 1989. do 2013. godine. Za

indikator ekonomske aktivnosti koriste godišnji realni BDP, a cikličku komponentu izdvajaju putem Hodrick-Prescottovog filtra. Zbog izbjegavanja statičnosti mjere usklađenosti u istraživanju koriste Cerqueira-Martinsov (2009) korelacijski indeks. Osim u cjelokupnom razdoblju, usklađenost poslovnih ciklusa promatraju i u četiri podrazdoblja: tranzicijskom razdoblju (do 2000.), pretkriznom razdoblju (2001.-2008.), vrhuncu krize (2009.) i razdoblju nakon krize (2010.-2013.). Rezultati njihovog istraživanja pokazuju da u pretkriznom razdoblju, paralelno sa započetim procesom integracije, raste usklađenost poslovnih ciklusa EU-25 s Bosnom i Hercegovinom, Hrvatskom, Makedonijom i Crnom Gorom, dok je za Albaniju, Kosovo i Srbiju usklađenost bila dosta manja i volatilnija. Ekonomska i financijska kriza, koja je snažno pogodila EU (ekonomska kontrakcija zemalja Zapadnog Balkana bila je manja nego u EU-25), razdvojila je poslovne cikluse zemalja zapadnog Balkana i EU-25. U razdoblju nakon krize dolazi do ponovne konvergencije, a čak i zemlje koje su u prethodnim razdobljima zabilježile nisku razinu usklađenosti, u ovom razdoblju ostvaruju visoku razinu usklađenosti poslovnog ciklusa s EU-25 (Hrvatska (0,909); Srbija (0,839); Albanija (0,850)). Zaključuju da Makedonija ima visoku usklađenost poslovnog ciklusa s EU, Albanija i Srbija nisku, dok rezultati za Hrvatsku nisu jednoznačni.

Usklađenost poslovnih ciklusa Hrvatske s osam najvažnijih hrvatskih vanjskotrgovinskih partnera u sklopu Europske unije (Austrija, Francuska, Njemačka, Mađarska, Italija, Nizozemska, Slovenija i Ujedinjeno Kraljevstvo) te EU-27 u razdoblju od 1997. do 2009. godine analizira Arčabić (2011). U tu svrhu izračunava jednostavni koeficijent korelacije (za ukupno razdoblje i dva podrazdoblja (1997Q1-2003Q2 i 2003Q3-2009Q4)) i petogodišnju centriranu pomičnu korelaciju. Koristi kvartalne podatke o realnom BDP-u, pri čemu poslovne cikluse procjenjuje putem dvije metode: (i) Hodrick-Prescottovim filtrom i (ii) godišnjim stopama rasta. Rezultati njegovog istraživanja pokazuju da je do 2002. godine usklađenost poslovnih ciklusa relativno niska i prevladava vremenski pomak u usklađenosti (Hrvatska zaostaje jedan do dva tromjesečja za poslovnim ciklusima europskih zemalja), da bi nakon 2002. došlo do izrazitog porasta usklađenosti. Dodatno, s porastom usklađenosti Hrvatska više ne zaostaje za poslovnim ciklusima zemalja EU, već se obrati u poslovnim ciklusima događaju istovremeno.

Kotarac, Kunovac i Ravnik (2017) analiziraju usklađenost poslovnih ciklusa Hrvatske sa sedam zemalja jezgre eurozone (Njemačka, Francuska, Italija, Španjolska, Nizozemska, Belgija i

Austrija) u razdoblju od 1998. do 2016. godine. Cikluse ekonomske aktivnosti izolirali su iz serija realnog BDP-a korištenjem jednostavnog univarijatnog HP filtra, a usklađenost ciklusa analiziraju putem tri mjere – korelacije, fazne sinkroniziranosti ciklusa (mjeri usklađenost predznaka ciklusa) i sličnosti ciklusa (usklađenost amplituda ciklusa). Autori navode da je hrvatski poslovni ciklus u razdoblju prije 2006. godine bio negativno koreliran s poslovnim ciklusom eurozone; neposredno prije globalne financijske krize navedena korelacija snažno raste, a zbog zajedničke kontrakcije ekonomske aktivnosti korelacija ostaje na razinama iznad 80% do 2011. godine. Od 2011. godine korelacije se postupno smanjuje. Prosječna fazna sinkroniziranost ciklusa Hrvatske s ciklusom zemalja jezgre eurozone u razdoblju do 2006. godine niža je od prosjeka ostalih promatranih zemalja; nakon toga snažno raste i neposredno pred izbijanje financijske krize dostiže gotovo savršenu sinkroniziranost. U razdoblju zajedničkih globalnih šokova (2008. i 2009.) sinkroniziranost Hrvatske s eurozonom ostaje na visokoj razini te za cjelokupno preostalo razdoblje ostaje viša od prosječne sinkroniziranosti rubnih zemalja. Sinkroniziranost ciklusa Hrvatske i eurozone pada isključivo u razdoblju od 2011. do 2013. godine (za vrijeme krize javnih financija u eurozoni). Pri samom kraju promatranog razdoblja hrvatski ciklus značajno je sinkroniziraniji u odnosu na prosjek rubnih zemalja EU-a kod kojih sinkroniziranost nastavlja opadati. Sličnost ciklusa Hrvatske i zemalja jezgre eurozone raste u razdoblju neposredno prije i tijekom globalne recesije, nakon čega se blago smanjuje. U razdoblju od 2006. do kraja 2015. sličnost ciklusa veća je za Hrvatsku u odnosu na prosjek rubnih zemalja, dok je u posljednjih nekoliko tromjesečja u neposrednoj blizini navedenog prosjeka. Kotarac, Kunovac i Ravnik (2017) zaključuju da uvođenje eura (i s time povezano prihvaćanje zajedničke protucikličke monetarne politike) ne bi trebalo biti značajan trošak za hrvatsku ekonomiju.

Usklađenost poslovnih ciklusa Hrvatske sa sedam novih zemalja EMU (Cipar, Estonija, Litva, Latvija, Malta, Slovačka i Slovenija) te Njemačkom, EU15, EMU19 i EU28 u razdoblju od 1995. do 2014. godine analiziraju Tomić i Demanuele (2017). U analizu uključuju sljedeće varijable: nezaposlenost, industrijsku proizvodnju, dug/BDP, realni BDP, realni BDP po glavi stanovnika, uvoz dobra i usluga, izvoz dobara i usluga, indeks potrošačkih cijena i realni efektivni tečaj. Podatke desezoniraju Census X12 procedurom, a cikličku komponentu iz vremenskih serija izoliraju Hodrick-Prescottovim filtrom. S obzirom na to da su podaci na kvartalnoj frekvenciji koriste parametar uglađivanja λ=1600. Postojanje jediničnog korijena testiraju proširenim

Dickey-Fullerovim testom, Philips-Perronovim testom i Kwiatkowski-Philips-Schmidt-Shinovim testom. Imajući u vidu ograničenja mjere sinkroniziranosti poslovnih ciklusa za prikladnost provođenja zajedničke monetarne politike, u istraživanju koriste i mjeru sličnosti poslovnih ciklusa koja je orijentirana na amplitudu poslovnih ciklusa. Rezultati njihovog istraživanja potvrđuju povećanje razine sinkroniziranosti i relativno stabilnu razinu sličnosti Hrvatskog poslovnog ciklusa sa novim zemljama EMU što upućuje da Hrvatska po promatranom kriteriju zadovoljava uvjet za monetarno integriranje. Ističu da se zaključci temelje na opažanju i da bi se mogli/trebali revidirati u budućnosti.

Arčabić (2018) analizira usklađenost poslovnih ciklusa u Europskoj uniji s gledišta BDP-a i nezaposlenosti u razdoblju od 2000. do 2017. godine. Za indikator ekonomske aktivnosti koristi kvartalne podatke o BDP-u i nezaposlenosti 28 zemalja članica EU-a te EU-28 agregiranim područjem. Podatke desezonira Census X12 metodom, a cikličku komponentu izračunava Hodrick-Prescottovim i Hamiltonovim filtrom. Usklađenost poslovnih ciklusa mjeri centriranim pomičnim koeficijentom korelacije s rasponom od 12 kvartala. Rezultati njegovog istraživanja pokazuju da Hrvatska od 2004. godine konstantno bilježi visoku razinu usklađenosti BDP-a i nezaposlenosti sa zemljama EU (s tek nekoliko kratkoročnih odstupanja prije početka financijske krize i za vrijeme dužničke krize u eurozoni). Arčabić (2018) zaključuje da bi uvođenje eura i prihvaćanje monetarne politike Europske središnje banke imalo niske troškove za Hrvatsku u pogledu sličnosti cikličkih kretanja BDP-a i nezaposlenosti.

Iz pregleda dosadašnje literature usklađenosti poslovnih ciklusa koja u svojoj analizi uključuje Hrvatsku, vidljivo je da većina radova cikličku komponentu ekonomske aktivnosti (bilo da se radi o BDP-u ili stopi nezaposlenosti) procjenjuje korištenjem Hodrick-Prescottovog filtra. Šonje i Vrbanc (2000) ističu nekoliko ograničenja kod korištenja navedenog filtra: kad se primjeni na velike uzorke sadrži centrirane četvrte diferencije i čini stacionarnim vremenske serije koje se diferenciranjem daju pretvoriti u stacionarne, čak i ako su većeg reda integracije (što je nepoželjno svojstvo koje se često zanemaruje); HP promjena u stopi rasta je često izrazito ciklična; HP filtar primijenjen na proces slučajnog hoda (engl. random walk) često stvara lažnu cikličnost; odabir parametra izglađivanja je arbitraran, a on utječe na ocjenu; HP filtar je statistički alat koji ne uzima u obzir ekonomsku ni strukturnu informaciju serije. Šonje i Vrbanc

(2000) ističu da upotreba HP filtra za izdvajanje cikličke komponente vremenskih serija nije opravdana jer u praksi obično nisu zadovoljene osnovne pretpostavke[19].

Dodatno, u većini dosadašnjih istraživanja usklađenost poslovnih ciklusa mjeri se Pearsonovim koeficijentom korelacije koji zanemaruje amplitudnu razliku (vrlo bitnu za provođenje zajedničke monetarne politike). Osim toga, upotreba Pearsonovog koeficijenta korelacije kod analize determinanti usklađenosti poslovnih ciklusa zahtijeva korištenje pomičnog vremenskog okvira, što uzrokuje značajni gubitak broja opažanja i stvara problem autokorelacije kod panel analize.

U skladu s navedenim ograničenjima dosadašnjih istraživanja usklađenosti poslovnih ciklusa za Hrvatsku u ovom radu će se koristiti podaci o cikličkoj komponenti BDP-a dobivene metodom proizvodne funkcije koja ima niz prednosti u odnosu na korištenje HP filtra. Osim toga, korištenjem Cerqueira-Martins korelacijskog indeksa dinamizirat će se mjera usklađenosti poslovnih ciklusa i ukloniti nedostaci korištenja Pearsonovog koeficijenta korelacije.

[19] Šonje i Vrbanc (2000) navode osnovne pretpostavke koje nisu zadovoljene: (i) kratkotrajna i stalna komponenta nisu korelirane (to podrazumijeva da su trend i ciklička komponenta generirane različitim ekonomskim snagama, što je često nekompatibilno s modelima poslovnih ciklusa.); (ii) izvorna vremenska serija integrirana je u red integracija (to često ne vrijedi za makroekonomske vremenske serije jer se obično pretpostavlja proces kod kojeg je red integracije jednak jedinici); (iii) kratkotrajna komponenta je proces bijelog šuma (to je također upitno); (iv) parametar kojim se kontrolira izglađenost trenda zadovoljavajući je (primjena HP filtra pokazala je da je teško precizno odrediti njegovu vrijednost).

3. ZNAČAJ FINANCIJSKE INTEGRACIJE ZA MONETARNO INTEGRIRANJE

U ovom poglavlju definirana je financijska integracija te su prikazane koristi i troškovi financijskog integriranja zemalja. Osim toga, objašnjen je značaj financijske integracije za učinkovitu alokaciju resursa, uglađivanje potrošnje i podjelu rizika. Konačno, dat je pregled načina mjerenja financijske integracije te korištenih indikatora u dosadašnjim sličnim istraživanjima kako bi se uz ograničenja dosadašnjih mjera, a uzimajući u obzir dostupnost podataka, izabrala odgovarajuća mjera financijske integracije kao glavne nezavisne varijable u empirijskom modelu utjecaja.

3.1. Pojam i definicija financijske integracije

Financijsko integriranje predstavlja proces uklanjanja financijskih prepreka kojim se omogućava slobodno kretanje kapitala između zemalja. Kroz proces financijske integracije financijska tržišta jedne zemlje postaju povezanija s financijskim tržištima drugih zemalja. To implicira povećanje kapitalnih tokova i tendenciju da se cijene i povrati na različite oblike financijske imovine izjednače. Financijska integracija zahtijeva eliminaciju nekih ili svih restrikcija prema financijskim institucijama drugih zemalja. Time bi strane financijske institucije mogle ponuditi prekogranične financijske usluge i uspostaviti kvalitetnije veze između bankovnih, kapitalnih i ostalih financijskih tržišta.

Povećanje stupnja integracije financijskih tržišta moguće je postići i u situaciji odsustva eksplicitnog dogovora između zemalja. Takvi oblici integracije uključuju npr. ulazak stranih banaka na domaće tržište, inozemno sudjelovanje na domaćem tržištu osiguranja, trgovanje vrijednosnicama u inozemstvu ili izravno zaduživanje domaćih kompanija na stranom tržištu.

Baele i ostali (2004) koriste sljedeću definiciju financijske integracije - Tržište za određeni skup financijskih instrumenata i/ili usluga je u potpunosti integrirano ako svi potencijalni sudionici tržišta imaju iste relevantne karakteristike:

- Suočavaju se s jedinstvenim skupom pravila kad se odluče koristiti s tim financijskim instrumentima i/ili uslugama;

- Imaju jednak pristup istom skupu financijskih instrumenata i/ili usluga;
- Tretirani su jednako kad su aktivni na tržištu.

Stavarek, Repkova i Gajdošova (2012) ističu da ovakva definicija financijske integracije sadrži tri važne značajke. Prvo, neovisna je o financijskoj strukturi unutar regija. Financijske strukture obuhvaćaju sve financijske posrednike - institucije i tržišta - i njihov međusobni odnos s obzirom na tokove sredstava od i prema kućanstvima, vladi i kompanijama.

Drugo, frikcije u procesu intermedijacije (tj. pristupu/ulaganju kapitala putem institucija/tržišta) mogu postojati i nakon što je proces financijske integracije završen. Financijska integracija bavi se simetričnim ili asimetričnim učincima postojećih frikcija na različitim područjima. Čak i u prisutnosti frikcija područja mogu biti financijski integrirana sve dok frikcije na tim područjima djeluju simetrično. Ako frikcije na područjima djeluju asimetrično, u tom slučaju proces financijske integracije ne može biti dovršen.

Treće, financijska integracija odvaja dvije sastavnice financijskog tržišta - ponudu i potražnju za investicijskim prilikama. Potpuna integracija zahtijeva isti pristup bankama ili platformama za trgovanje, obračun i namiru platnih transakcija kako za ulagače (potražnja za investicijskim prilikama), tako i za kompanije (ponuda investicijskih prilika) neovisno o regiji njihovog porijekla. Dodatno, jednom kad je pristup omogućen, potpuna integracija zahtijeva da ne postoji diskriminacija tržišnih sudionika temeljena na njihovoj geografskoj lokaciji. Ako struktura sistematično diskriminira strane investicijske prilike zbog nacionalnih legalnih ograničenja onda takvo područje nije financijski integrirano. Stavarek, Repkova i Gajdošova (2012) ističu da područje također može biti djelomično integrirano.

Baltzer i ostali (2008) ističu da je zakon jedne cijene izravna implikacija Baelove i ostalih (2004) definicije za koju ističu da predstavlja situaciju savršene integracije. Ako se ekonomski agenti susreću s istim pravilima, imaju isti pristup i tretirani su jednako, bilo kakva cjenovna razlika između identične imovine bit će odmah arbitrirana. Autori navode da postoje slučajevi u kojima zakon jedne cijene nije izravno primjenjiv. Tako npr., ako određenoj imovini nije dopušteno da bude izlistana na burzi druge regije (zemlje) onda nije moguće primijeniti zakon jedne cijene kao temelj za mjerenje stupnja financijske integracije. Stoga, iako je zakon jedne cijene vrlo privlačan koncept, nedostaje mu jedan važan čimbenik - određivanje je li investicijska prilika subjekt diskriminirajuće prakse ili ne. Također, određene vrijednosnice (prvenstveno dionice i

korporativne obveznice) karakteriziraju različiti novčani tokovi i heterogeni izvori rizika zbog čega njihove cijene nisu izravno usporedive

Financijska integracija ne uključuje samo integraciju financijskih tržišta i usluga već može imati i druge oblike koji ne moraju biti međusobno povezani niti predstavljaju napredniji stupanj procesa integracije. Libescher i ostali (2006) ističu da financijska integracija može imati više oblika i različitih apekata:

- Monetarna integracija putem valutnog područja (Europa, Zapadna i Središnja Afrika) ili putem dolarizacije (Latinska Amerika i Karibi);
- Liberalizacija kapitalnog računa;
- Podugovaranje financijskih usluga ili infrastrukture u inozemstvu, kao u slučaju izlistavanja vrijednosnih papira na inozemnim burzama;
- Strani ulaz (engl. foreign entry);
- Regulatorna konvergencija i harmonizacija.

Guha i ostali (2004) razlikuju ukupnu, izravnu i neizravnu financijsku integraciju. Autori ističu da se izravna financijska integracija (pod kojom smatraju integraciju tržišta kapitala) izražava odstupanjem od zakona jedne cijene. Drugim riječima, kad postoji izravna financijska integracija investitor može očekivati isti povrat na ulaganje u financijske instrumente (prilagođen za rizik) na različitim tržištima. Neizravna financijska integracija odnosi se na situaciju u kojoj je povrat na ulaganje u jednoj zemlji neizravno povezan s povratom na ulaganje u drugim zemljama. Ukupna financijska integracija uključuje izravnu i neizravnu financijsku integraciju.

Stupanj financijske integracije može varirati od savršene financijske integracije do savršene financijske dezintegracije. Kada očekivane realne kamatne stope nisu jednake na promatranim tržištima onda se za takva tržišta kaže da su segmentirana. Segmentirana tržišta rezultat su nedostatka financijske integracije, a pojavljuju se zbog visokih transakcijskih troškova uključenih u proces arbitraže ili zbog tržišne neučinkovitosti (Guha i ostali, 2004).

Financijska integracija može ojačati putem provedbe formalnih međunarodnih sporazuma, i to na dva načina (Ho, 2009). U prvom redu, prihvaćanjem odredbi da se zajedničkim ili usklađenim politikama odgovori na financijske poremećaje. Drugo, uklanjanjem ograničenja na prekogranične financijske operacije partnerskih zemalja, kao i usklađivanjem propisa između

financijskih sustava zemalja, kako bi se postiglo potpuno ujedinjenje njihovih regionalnih financijskih tržišta, poreza i regulativa.

S druge strane, Japelli i Pagano (2008) navode nekoliko prepreka daljnjem financijskom integriranju, tj. djelovanju zakona jedne cijene. Prvo, ako dvije zemlje imaju različite valute onda fluktuacije deviznog tečaja mogu stvoriti dodatni rizik. Stoga će ulagači zahtijevati premiju rizika za držanje vrijednosnice denominirane u stranoj valuti. Čak i ako nema fluktuacija deviznog tečaja, transakcijski troškovi koji nastaju zbog konverzije strane valute u domaću valutu (i obrnuto) induciraju odstupanje od međunarodne arbitraže.
Druga prepreka integraciji proizlazi iz razlika u porezima (poreznim sustavima) koji djeluju poput klina na oporezovani trošak kapitala u različitim zemljama.
Dalje, razlike u regulativi i provedbi mogu spriječiti financijske posrednike (intermedijare) da se ravnopravno natječu preko nacionalnih granica. Tako npr., financijska regulativa može stvoriti veće prepreke ulasku stranih posrednika na tržište u odnosu na ulazak domaćih posrednika; slično tome sudska učinkovitost može se razlikovati od zemlje do zemlje pa zahtijeva od financijskih posrednika da naplate različite kamatne stope za kompenzaciju očekivanih troškova u slučaju neplaćanja ugovorenih obveza.
Konačno, prepreke financijskom integriranju mogu proizaći iz asimetričnih informacija između potencijalnih stranih i domaćih sudionika. Japelli i Pagano (2008) ističu da je ovo posebno važno na tržištu kredita na kojem se znanje lokalnih pozajmljivača koristi za stjecanje informacijske prednosti nad stranim pozajmljivačima.

Kalemli-Ozcan i Manganelli (2008) klasificiraju prepreke financijskom integriranju u tri glavne kategorije:

- Psihološke/informacijske prepreke – mnoga istraživanja potvrđuju nezanemarive psihološke i kulturološke prepreke financijskom integriranju. Na primjer, kulturološke razlike i nepovjerenje objašnjavaju značajan dio bilateralnih financijskih i trgovinskih tokova. Osim toga, varijable koje odražavaju informacijske asimetrije među zemljama (npr. telefonski troškovi, vrijeme trgovanja, opticaj stranih novina i sl.) značajno koreliraju s prekograničnim tokovima kapitala.

- Regulatorne/pravne prepreke – osnovni preduvjet financijskog integriranja je uklanjanje svih zakonskih i regulatornih razlika koje diskriminiraju ekonomske agente na temelju njihove lokacije.
- Tehničke/infrastrukturne prepreke – tehničke tržišne infrastrukture također su ključne za financijsko integriranje. Prepreke trgovanju vrijednosnim papirima preko nacionalnih granica sprječavaju djelovanje arbitražnih sila i potiču kršenje zakona jedne cijene.

Snažan poticaj financijskoj integraciji europskih zemalja dalo je uvođenje eura od strane 12 zemalja članica Europske unije 1999. godine. Naime, uvođenjem eura eliminiran je tečajni rizik, kao i troškovi koji su proizlaze iz deviznih transakcija unutar eurozone. To je izravno utjecalo na uklanjanje jedne od glavnih prepreka za financijsku integraciju.

Osim toga, proces monetarnog ujedinjenja potaknuo je cijeli niz političkih djelovanja i odgovora privatnog sektora kojim su otklonjene mnoge ostale regulatorne prepreke procesu daljnje financijske integracije. Uklonjene su kontrole kretanja kapitala, donesene su direktive za bankarske i ostale financijske usluge kojima su stvoreni jednaki uvjeti na kreditnom tržištu i tržištima vrijednosnih papira te homogenizirani propisi koji uređuju izdavanje javnog duga. Uklanjanjem dijela prepreka za financijsku integraciju potaknuta je učinkovitost financijskih posrednika i tržišta u zemljama u kojima je financijski sustav slabije razvijen i jače reguliran. U mjeri u kojoj veća financijska učinkovitost potiče potražnju za sredstvima i financijskim uslugama, potaknut je rast domaćeg financijskog tržišta i olakšan pristup stranim tržištima i posrednicima.

3.2. Koristi i troškovi financijske integracije

Financijska integracija generira brojne izravne i neizravne koristi, ali i rizike za zemlje. Mnogi autori ističu potrebu boljeg poznavanja koristi i troškova da bi se minimizirali troškovi i maksimizirale koristi financijskog integriranja zemalja. Iskustva zadnje globalne financijske krize ukazala su na važnost ove debate. U nastavku su prikazane koristi i troškovi financijske integracije.

3.2.1. Koristi financijske integracije

Financijsko integriranje zemalja sa sobom nosi određene koristi. Baele i ostali (2004) ističu tri široko prihvaćene, međusobno povezane koristi financijske integracije:

1) Više prilika za podjelu rizika (engl. risk sharing) i diversifikaciju rizika;
2) Učinkovitija alokacija kapitala između investicijskih prilika;
3) potencijal za veći rast.

Stavarek, Repkova i Gajdošova (2012) ističu i financijski razvoj kao korisnu posljedicu financijskog integriranja. Na slici 9. prikazane su koristi financijske integracije.

Slika 9. Koristi financijske integracije

Izvor: Stavarek, Repkova i Gajdošova (2012)

Ekonomska teorija predviđa da financijska integracija olakšava podjelu rizika (Jappelli i Pagano, 2008). Integracija u veća tržišta, pa čak i formiranje većih tržišta korisno je za kompanije te za financijska tržišta i institucije. Baele i ostali (2004) ističu da financijska integracija pruža dodatne mogućnosti za kompanije i kućanstva za podjelu financijskog rizika i za intertemporalno uglađivanje potrošnje.

Podjela rizika omogućava financiranje visokorizičnih projekata s potencijalno višim prinosima. Mogućnost podjele rizika poboljšava financijska tržišta i omogućava ulagačima koji su averzni

prema riziku zaštitu od negativnih šokova. S obzirom na to da financijska tržišta i institucije bolje upravljaju kreditnim rizikom, financijska integracija može ukloniti određene oblike kreditnih ograničenja s kojima se suočavaju ulagači (Stavarek, Repkova i Gajdošova, 2012). Zakon velikih brojeva garantira manju izloženost kreditnom riziku kako broj klijenata raste. Također, individualni rizici mogu se smanjiti integriranjem u veće tržište.

Financijska integracija omogućava diversifikaciju portfelja kroz dostupnost dodatnih financijskih instrumenata. Na taj način kućanstva mogu diversificirati dio rizika koji proizlazi iz šokova specifičnih za zemlju (engl. country specific shocks).
Slično tome, financijska integracija omogućava bankama međunarodnu diversificiraju njihovog kreditnog portfelja. Ovaj oblik diversifikacije trebao bi pomoći kućanstvima da uglade dohodak jer šokovi karakteristični za zemlju ne bi utjecali na domaću potrošnju, već bi se neutralizirali zaduživanjem u inozemstvu ili držanjem strane imovine (Jappelli i Pagano, 2008).

Općeprihvaćeno gledište je da veći stupanj financijske integracije omogućava učinkovitiju alokaciju kapitala. Integrirano financijsko tržište uklanja sve oblike zapreka trgovanju financijskom imovinom i kretanju kapitala čime omogućava učinkovitiju alokaciju financijskih sredstava za investicije i proizvodnju. Dodatno, ulagačima je dopušteno da ulažu sredstva gdje god oni vjeruju da će ta sredstva biti uložena u najproduktivnije svrhe (Stavarek, Repkova i Gajdošova, 2012). Omogućavanjem produktivnijih investicijskih prilika automatski će se realokacija sredstava usmjeriti prema takvim prilikama (Baele i ostali, 2004).

Kao glavnu prednost integracije financijskih sustava putem formalnih sporazuma Ho (2009) ističe iskorištavanje ekonomije obujma koje omogućava poduzećima (pogotovo malim i srednjim), koja se uglavnom suočavaju s kreditnim ograničenjima, bolji pristup financijskim tržištima. Također, integriranjem u veće tržište može se smanjiti individualni rizik i poboljšati diversifikacija portfelja.

Kalemli-Ozcan i Manganelli (2008) pokazuju da putem otvaranja pristupa stranim tržištima financijska integracija omogućava širi raspon izvora financiranja, ulagačkih prilika te potiče stvaranje dubljeg i likvidnijeg tržišta. Na taj način informacije se učinkovitije prikupljaju i obrađuju, a time se potiče alokacija kapitala na mnogo učinkovitiji način.

Teorijska literatura navodi različite mehanizme putem kojih financijska integracija može utjecati na ekonomski rast. U neoklasičnom modelu rasta svi učinci generirani su kroz kapitalne tokove. U standardnom modelu rasta otvaranje međunarodnih tržišta kapitala generira tokove od kapitalno obilnih prema kapitalno oskudnim zemljama čime ubrzava konvergenciju (potiče kratkoročni rast) u siromašnijim zemljama (Stavarek, Repkova i Gajdošova, 2012). Promatrano u sofisticiranijem kontekstu, kapitalni tokovi mogu osloboditi zemlju od kreditnih ograničenja i time ekonomskim agentima omogućiti sredstva za poduzimanje produktivnijih investicija (Bonfiglioli, 2008). Osim toga, u standardnom neoklasičnom modelu rasta financijska integracija poboljšava funkcioniranje domaćeg financijskog sustava kroz poticanje konkurencije i uvoz financijskih usluga čime u konačnici pozitivno utječe na rast (Levine, 2001).
Obstfeld (1994) ističe alternativno gledište u kojem međunarodna mobilnost kapitala utječe na produktivnost neovisno o investicijama. Naime, putem međunarodne diversifikacije rizika međunarodna mobilnost kapitala omogućava uzimanje više rizika (engl. risk taking) u domaćim inovacijskim aktivnostima čime potiče ekonomski rast.

Levine (1997) ističe da financijski sustav ima tri važne funkcije:

- smanjuje nesigurnost olakšavanjem trgovanja, hedžiranja, diversifikacije i udruživanjem rizika (engl. risk pooling);
- potiče učinkovitu alokaciju resursa;
- mobilizira štednju.

Navedene funkcije utječu na ekonomski rast putem akumulacije kapitala i tehnologije na vrlo intuitivan način. Mogućnost podjele rizika omogućava financiranje projekata s visokim stopama povrata, ali s visokim rizikom. Uz pomoć intermedijara (koji su specijalizirani u prikupljanju i širenju informacija) alokacija resursa može se obaviti učinkovitije i pri nižim troškovima. Također, vlasnici projekata s nedovoljnim početnim kapitalom mogu se obratiti intermedijaru koji mobilizira štednju i na taj način pokriva inicijalne troškove. Ovi kanali su kvantitativno vrlo važni. Brojne analize i studije na razini zemalja i između zemalja (kao i na industrijskoj razini i na razini kompanija) potvrđuju da je funkcioniranje financijskog sustava ključno za ostvarivanje

ekonomskog rasta. Ekonomski rast i financijski razvoj[20] snažno su isprepleteni, stoga je teško izvući čvrste zaključke o uzročno-posljedičnoj vezi (Levine, 1997).

Glavni kanal putem kojeg financijska integracija potiče domaći financijski razvoj je povećanje domaće konkurencije sa sofisticiranijim i jeftinijim stranim intermedijarima (Jappelli i Pagano, 2008). Pritisak strane konkurencije smanjuje troškove financijskih usluga kompanijama i kućanstvima iz zemalja sa slabije razvijenim financijskim sustavima i na taj način produbljuje domaće financijsko tržište. Dodatno, ulazak stranih intermedijara na domaće tržište može proširiti ponudu financijskih usluga. Proces spajanja može potaknuti veću učinkovitost banaka što će u konačnici smanjiti troškove posredovanja. Dakle, povećanje konkurencije u kombinaciji s rezanjem troškova vodi prema bogatijoj ponudi kredita i nižim kamatnim stopama.

Drugi kanal putem kojeg financijska integracija utječe na financijski razvoj je kroz usklađivanje nacionalnih propisa (računovodstveni standardi, sigurnosni propisi, nadzor nad bankama, korporativno upravljanje) kojeg nameće sam proces integracije (Jappelli i Pagano, 2008). U obujmu u kojem regulatorno usklađivanje promiče konvergenciju prema najboljim međunarodnim standardima, unaprijedit će domaći financijski razvoj i potaknuti ulazak stranih financijskih posrednika u slabije razvijenim zemljama.

3.2.2. Troškovi financijske integracije

Osim potencijalnih koristi, financijsko integriranje zemalja može uzrokovati i značajne troškove. U svijetu nesavršenih tržišta kapitala integracija može učiniti zemlje ranjivijima na vanjske makroekonomske šokove i financijske krize. Stavarek, Repkova i Gajdošova (2012) ističu da učinci zaraze, pojačani promjenjivošću i ponašanjem stada[21] (engl. herding behaviour) od strane financijskih institucija, mogu povećati volatilnost outputa i potrošnje, umjesto da ih smanjuju kao što to zagovara literatura o podjeli rizika (engl. risk sharing). Učinci zaraze posebno su problematični za rastuće ekonomije jer su zemlje razvijenijim financijskim sustavima (poput

[20] Financijski razvoj je proces uvođenja financijskh inovacija te institucionalnih i organizacijskih poboljšanja u financijskom sustavu. Financijski razvoj utječe na smanjenje asimetričnih informacija, povećava stupanj razvijenosti tržišta i mogućnosti ugovaranja, smanjuje transakcijske troškove i povećava konkurentnost.

[21] Učinak koji nastaje zbog tendencije pojedinaca za oponašanjem racionalnih i neracionalnih akcija veće skupine

dijela zemalja eurozone) manje osjetljive na financijske krize od zemalja sa slabije razvijenim financijskim sustavima. Na slici 10. prikazani su troškovi financijske integracije.

Agenor (2003) ističe glavne troškove financijskog integriranja:

a) Koncentracija kapitalnih tokova i otežani pristup kapitalu;
b) Pogrešna raspodjela (engl. misallocation) kapitalnih tokova;
c) Gubitak makroekonomske stabilnosti;
d) Procikličnost kratkoročnih kapitalnih tokova;
e) Volatilnost kapitalnih tokova, zaraza i ponašanje stada (engl. herding);
f) Rizik ulaska stranih banaka.

Slika 10. Troškovi financijske integracije

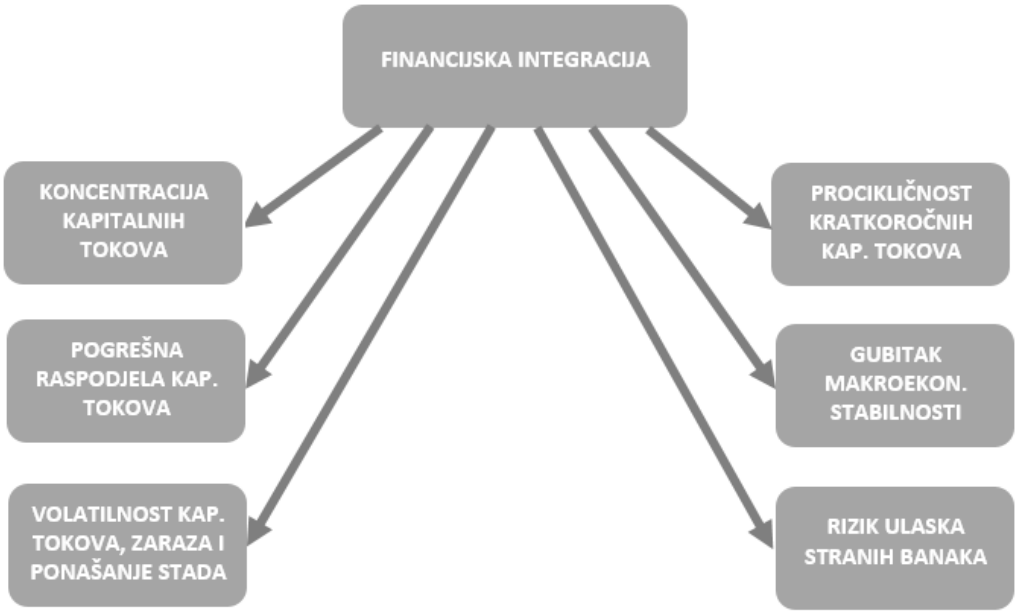

Izvor: Agenor (2003)

a) Koncentracija kapitalnih tokova i otežani pristup kapitalu

Postoji mnoštvo dokaza koji potvrđuju da prekogranični kapitalni tokovi imaju sklonost snažnoj koncentraciji na manji broj zemalja primateljica (Agenor, 2003). Primjerice, snažni porast kapitalnih priljeva u ranim 1990-im godinama usmjeren je prema manjem broju velikih zemalja Latinske Amerike i Azije sa srednjom razinom dohotka (Fernandez-Arias and Montiel, 1996). Udio privatnih kapitalnih tokova usmjerenog prema zemljama niskog dohotka zapravo je opao (s

razine koja je već bila niska), dok je udio privatnih kapitalnih tokova deset najvećih zemalja primateljica kapitala značajno porastao. Vrlo malo kapitalnih tokova usmjereno je prema subsaharskoj Africi, a većina tih tokova odnosi se na tek nekoliko zemalja sa značajnim prirodnim resursima poput Angole, Nigerije i Južne Afrike (Basu i Srinivasan, 2002).

Agenor (2003) ističe da su male rastuće ekonomije često isključene (engl. rationed out) iz svjetskih tržišta kapitala. Dodatno, među zemljama s većim potencijalom pristupu tržištima kapitala (kao npr. proizvođači nafte) dostupnost resursa može biti asimetrična. Navedene zemlje mogu pozajmljivati samo u dobrim vremenima, dok se u lošim vremenima suočavaju s kreditnim ograničenjima. Jasno da je u takvim uvjetima jedna od ključnih koristi pristupa svjetskim tržištima kapitala – mogućnost pozajmljivanja u svrhu uglađivanja potrošnje kod pojave privremenih negativnih šokova, jednostavno iluzija.

b) Pogrešna raspodjela kapitalnih tokova

Iako priljevi kapitala, koji su povezani s otvaranjem kapitalnog računa, mogu povećati domaće investicije, njihov utjecaj na dugoročni rast može biti ograničen (pa čak i zanemariv) ako se takvi priljevi koriste za financiranje špekulativnih ili nisko kvalitetnih domaćih investicija (npr. ulaganja u nekretnine). Niskoproduktivne investicije u nerazmjenjivi (engl. non tradeable) sektor mogu tijekom vremena smanjiti izvozni kapacitet zemlje i uzrokovati rast vanjskih neravnoteža (Stavarek, Repkova i Gajdošova, 2012).

Agenor (2003) ističe da pogrešna raspodjela kapitalnih priljeva može biti posljedica distorzija u domaćem financijskom sistemu. U zemljama sa slabim bankama (banke s niskom ili negativnom neto vrijednošću ili banke s velikim udjelom rizične imovine) i lošim nadzorom financijskog sustava, izravna ili neizravna intermedijacija velike količine sredstava od strane bankovnog sustava može povećati probleme moralnog hazarda povezane s osiguranjem depozita. To znači da se zajmodavci mogu uključiti u rizičnije i koncentriranije kreditne operacije.

Problem asimetričnih informacija i njihov utjecaj na iskorištavanje prednosti kapitalnih priljeva istražuju Razin, Sadka i Yuen (1999) koji se fokusiraju na izravne strane investicije. Autori ističu da kroz izravne strane investicije (i transfer kontrole koji one nose) strani ulagači imaju insajderske informacije o produktivnosti kompanija u koju ulažu. To im daje informacijsku prednost nad slabije informiranim domaćim ulagačima (čiji udio nije dovoljan da im omogući

kontrolu) koja im omogućava da zadrže visoko produktivne kompanije, a one nisko produktivne prodaju domaćim ulagačima. Problem negativne selekcije može dovesti do preinvestiranja (engl. over-investment) od strane stranih ulagača (Agenor, 2003).

c) Gubitak makroekonomske stabilnosti

Veliki priljevi kapitala inducirani financijskom otvorenošću zemalja mogu imati neželjene makroekonomske učinke koji uključuju rapidnu monetarnu ekspanziju (zbog poteškoća kod provođenja politike sterilizacije), inflacijskog pritiska (zbog učinka kapitalnih priljeva na domaću potrošnju), aprecijaciju realnog deviznog tečaja i povećanje deficita tekućeg računa (Agenor, 2003).

U sustavu fluktuirajućih deviznih tečajeva rastući vanjski deficit potiče deprecijaciju valute koja može utjecati na prilagođavanje relativnih cijena i inducirati automatsku korekciju kretanja trgovinskih tokova. S druge strane, u sustavu fiksnih deviznih tečajeva gubitak konkurentnosti i rastuća vanjska neravnoteža mogu značajno smanjiti povjerenje u održivost deviznog režima i na taj način povećati financijsku nestabilnost i precipitirati valutnu krizu (Stavarek, Repkova i Gajdošova, 2012).

d) Procikličnost kratkoročnih kapitalnih tokova

Stavarek, Repkova i Gajdošova (2012) ističu da procikličnost kratkoročnih kapitalnih tokova može imati negativne učinke i povećati makroekonomsku nestabilnost: pozitivni šokovi mogu privući velike priljeve kapitala i potaknuti potrošnju na razini koja nije održiva u dugom roku, prisiljavajući zemlje na pretjeranu prilagodbu (engl. over-adjust) kod pojave negativnih šokova.

Prociklično kretanje kapitala nije problematično ukoliko proizlazi iz promjena u potražnji zemalja. Međutim, u praksi procikličnost najčešće proizlazi iz vanjskih čimbenika na strani ponude (npr. nagla promjena u uvjetima trgovanja), koji mijenjaju percepciju rizika kod zajmodavaca i time pojačavaju utjecaj šokova (Agenor, 2003).

Agenor (2003) ističe dva razloga procikličnog kretanja kratkoročnih kapitalnih tokova. Prvo, ekonomski šokovi su veći i češći u rastućim ekonomijama, što je posljedica uske proizvodne baze takvih zemalja i njihove veće ovisnosti o izvozu primarnih roba. Zajednički negativni šok može izazvati pogoršanje kreditne sposobnosti navedenih zemalja zbog nagle promjene u percepciji

rizika. To može uzrokovati istiskivanje sa svjetskih tržišta kapitala onih zajmoprimaca koji imaju graničnu kreditnu sposobnost.
Drugo, problemi asimetričnih informacija mogu potaknuti ponašanje stada (engl. herding behaviour) jer djelomično informirani ulagači mogu požuriti s masovnim povlačenjem kapitala zbog pojave negativnih šokova.

Postoje dokazi da kratkoročni kapitalni tokovi u rastućim ekonomijama djeluju prociklično. Naime, istraživanje Svjetske banke provedeno na uzorku 33 rastuće ekonomije u razdoblju od 1986. do 1998. godine potvrđuje da kapitalni tokovi rastu u slučaju ekonomskog rasta, a opadaju kod pojave negativnih stopa ekonomskog rasta. Za razliku od kratkoročnih kapitalnih tokova, srednjoročni i dugoročni dug djeluju slabo protuciklički (Agenor, 2003).

e) Volatilnost kapitalnih tokova, zaraza i ponašanje stada

Stavarek, Repkova i Gajdošova (2012) ističu da visoki stupanj financijske integracije (i financijske otvorenosti) može pridonijeti volatilnosti kapitalnih tokova - specifičnom ostvarenju u kojem dolazi do zaokreta u kratkoročnim kretanjima kapitala, usko povezanih sa špekulativnim pritiscima na domaću valutu. Mogućnost pojave velikih zaokreta u kratkoročnim kapitalnim tokovima povećava rizik suočavanja zajmoprimaca s visokim troškovima "bijega u likvidnost" (engl. liquidity run), a viša razina kratkoročnog duga u odnosu na međunarodne pričuve zemlje (koja se zadužuje) implicira veći rizik od pojave takvih troškova.

Stupanj volatilnosti kapitalnih tokova povezan je sa stvarnim i percipiranim kretanjima u domaćim ekonomskim fundamentima, te vanjskim čimbenicima kao što su npr. kretanja svjetskih kamatnih stopa (Stavarek, Repkova i Gajdošova, 2012). Općenito gledajući, ulagačev sentiment (posebno visoko špekulativnih hedge fondova) konstantno se mijenja s pojavom novih informacija, čime se stvara mogućnost pregrijavanja tržišta i generiranja financijskih kriza s velikim ekonomskim i socijalnim troškovima. Kratkoročni portfeljni tokovi posebno su osjetljivi na učinke zaraze i učinke ponašanja stada (Agenor, 2003).

Iako se ponašanje stada obično smatra neracionalnim ponašanjem, Devenow i Welch (1996) ističu da takvo ponašanje može biti racionalno u prisustvu nekoliko učinaka:

- isplatnih eksternalija - povezane su s činjenicom da isplata agentu (ulagaču) koji obavlja specifičnu radnju može biti pozitivno povezana s nizom drugih agenata koji obavljaju istu radnju;
- razmatranja principal-agent - proizlaze iz činjenice da portfeljni menadžer, kako bi održao ili poboljšao svoj ugled na nesavršeno informiranim tržištima, preferira "skrivanje u stadu" (engl. hide in the herd) kako bi izbjegao evaluaciju (i/ili kritiku), ili "nadzor stada" (engl. ride the herd) kako bi dokazao vlastitu kvalitetu;
- informacijskih kaskada - koje proizlaze iz činjenice da (mali) agenti koji tek počinju s ulaganjima u zemlju smatraju optimalnim ignorirati vlastite informacije i slijediti ponašanje većih i uglednijih ulagača.

Ponašanje stada, bilo ono racionalno ili iracionalno, može uzrokovati velika kretanja od i prema određenim oblicima imovine i na taj način pojačati fluktuacije cijena imovine i kapitalnih tokova (Stavarek, Repkova i Gajdošova (2012).

Agenor (2003) ističe da volatilnost kapitalnih tokova također može biti posljedica učinaka zaraze. Financijska zaraza događa se kad zemlja ima velike kapitalne odljeve zbog percepcije ulagača o ranjivosti valute ili zbog gubitka povjerenja u ekonomski prosperitet, a kao posljedica događanja u nekoj drugoj zemlji.

Osim putem financijskih poveznica, Dornbusch, Park i Claessens (2000) ističu još dva kanala zaraze s neizravnim učincima na volatilnost kapitalnih tokova: kanal trgovinskih poveznica (šokovi u uvjetima trgovanja) i kanal konkurentskih deprecijacija (učinak konkurentnosti).

Primjer šokova u uvjetima trgovanja predstavljaju događaji iz azijske krize koji su doveli do snažnog pada potražnje za uvozom od strane zemalja pogođenih krizom i naglog pada svjetskih cijena roba. Povećanjem stupnja nesigurnosti vezanog za kratkoročni ekonomski rast zemlje, šokovi u uvjetima trgovanja mogu se pretvoriti u financijsku zarazu - što se dogodilo u Čileu krajem 1997. i početkom 1998 godine (Agenor, 2003).

Konkurentske deprecijacije vezane su za deprecijaciju valute putem koje zemlja smanjuje konkurentnost drugih zemalja s kojima se natječe na trećim tržištima, tj. stvara pritisak na valute susjednih zemalja. To je posebno izraženo ako zemlje imaju fiksni devizni tečaj (Dornbusch, Park i Claessens, 2000). Kao primjer konkurentske deprecijacije Agenor (2003) navodi oštru deprecijaciju tajlandskog bahta koja je početkom 1997. godine stvorila pritisak na susjedne

zemlje (i uzrokovala veliki gubitak njihove konkurentnosti) koje su zadržale fiksni devizni tečaj prema bahtu.

f) Rizik ulaska stranih banaka

Iako ulazak stranih banaka na domaće tržište ima određene koristi, također može uzrokovati troškove. Strane banke mogu ograničiti kreditiranje manjih poduzeća (koja uglavnom djeluju u nerazmjenjivom sektoru) u većoj mjeri nego domaće banke, i umjesto toga koncentrirati se na veća i jača poduzeća (koja su često orijentirana na izvoz). Ako strane banke koriste strategiju fokusiranja svojih kreditnih operacija isključivo na poduzeća s najvišim stupnjem kreditne sposobnosti, njihova prisutnost vrlo vjerojatno neće pridonijeti sveukupnom povećanju učinkovitosti u financijskom sektoru. Još važnije, ograničavanje kredita manjim poduzećima može imati negativan učinak na output, zaposlenost i distribuciju dohotka (Stavarek, Repkova i Gajdošova, 2012).

Agenor (2003) ističe da ulazak stranih banaka (koje imaju manje operativne troškove) stvara domaćim bankama pritiske za spajanjima kako bi ostale konkurentne. Proces koncentracije (koji također nastaje preuzimanjem domaćih banaka od strane stranih banaka) može stvoriti banke koje su "prevelike da propadnu" (engl. too big to fail) - jer se monetarne vlasti boje da pad jedne velike banke može ozbiljno poremetiti financijsko tržište i uzrokovati socijalne probleme. To u konačnici može stvoriti problem moralnog hazarda – znajući da postoji (implicitna) sigurnosna mreža, banke postaju nepažljivije u alokaciji kredita i analizi potencijalnih zajmoprimaca. Dodatno, koncentracija banaka može stvoriti monopolističku moć koja smanjuje učinkovitost bankovnog sustava i dostupnost kredita. Preciznije, visok stupanj koncentracije bankovnog sustava negativno utječe na output i rast povećanjem razlika (engl. spreads) u kamatnim stopama (više kamatne stope na kredite i niže kamatne stope na depozite u odnosu na konkurentno tržište kredita i depozita) i smanjuje obujam kredita u odnosu na konkurentniji sustav.

Ulazak stranih banaka ne mora nužno voditi povećanoj stabilnosti domaćeg financijskog sustava jer njihova prisutnost sama po sebi ne čini manje vjerojatnom pojave sustavnih bankovnih kriza. Banke u slučaju dugotrajnije i dublje recesije, koja vodi do masovnog povećanja nenaplativih kredita, imaju tendenciju provođenja strategije "reži i bježi" (engl. cut and run) i stoga ne moraju predstavljati stabilan izvor domaćeg financiranja (Agenor, 2003). Također, često provođena strategija je "bijeg u kvalitetu" (engl. flight to quality) koja je primijenjena tijekom azijske krize.

Naime, tijekom navedene krize sredstva iz manjih banaka prebacivala su se u veće banke (naročito banke u stranom vlasništvu) što je značajno doprinijelo nestabilnosti domaće depozitne baze i financijskog sustava općenito.

U prisustvu trgovinskih distorzija, liberalizacija kapitalnog računa može inducirati kapitalne priljeve u sektore u kojima zemlja nema komparativne prednosti (Eichengreen, 2001). Boyd i Smith (1992) ističu da financijska integracija kod zemalja sa slabim institucijama i politikama (nedovoljno snažni financijski i pravni sustav) potiče odljev kapitala prema kapitalno obilnijim zemljama (s boljim institucijama).

S teorijskog gledišta financijska integracija nije dovoljna za postizanje najučinkovitijeg ishoda, osim ako ne rezultira tržištima na kojima je moguće u potpunosti hedžirati rizik - savršenim tržištima (engl. complete markets). Kad su financijska tržišta savršena, agenti averzni prema riziku mogu postići potpunu podjelu rizika (engl. risk sharing) i savršeno uglađivanje potrošnje (engl. consumption smoothing).

Hart (1975) ističe da proširenje ponude financijskih instrumenata može garantirati korisnost jedino u slučaju da novouvedeni instrumenti nude dovoljno mogućnosti hedžiranja da bi se završilo stvaranje kompletnog tržišta. U ostalim slučajevima moguće je da se svi agenti nađu u lošijem položaju jer povrat na imovinu u različitim zemljama ovisi o cijenama u tim zemljama. Uvođenje nove vrijednosnice može narušiti cijenu postojećih vrijednosnica i na taj način smanjiti mogućnosti podjele rizika (umjesto da je poveća). U tom kontekstu, uvođenje novih financijskih instrumenata u situaciji nesavršenih tržišta može biti štetno za agente averzne prema riziku. Dakle, financijska integracija, osim ako ne rezultira savršenim tržištima, ne mora voditi većoj dobrobiti za sve agente.

Dodatno, u slučaju da financijski sustav kombinira bankovna i financijska tržišta, financijska tržišta ograničavaju bankovna tržišta jer agenti imaju mogućnost izlaska iz bankovnih aranžmana i ulaska na financijska tržišta. U tom slučaju mješoviti financijski sustav ne funkcionira bolje nego financijsko tržište zasebno. Iz tog razloga, kad se zemlje s različitim financijskim sustavima financijski otvore jedna prema drugoj nije sigurno da će obje profitirati.

Baele i ostali (2004) ističu da učinkovitija alokacija kapitala, koja koristi većini, ipak može štetiti nekima. Naime, modificiranjem prevladavajuće financijske strukture financijska integracija može naškoditi nekim sadašnjim financijskim institucijama putem spajanja ili gubitka tržišnog udjela.

Autori zaključuju da putem financijske integracije dolazi do transformacije financijskih sustava svih zemalja, stoga bi se sam proces financijske integracije trebao pažljivo promatrati da bi se utvrdilo evoluiraju li financijska tržišta prema učinkovitijim strukturama.

3.3. Važnost financijske integracije u procesu monetarnog integriranja

Važnost financijske integracije za Hrvatsku kao zemlju koja je u procesu prihvaćanja eura[22] kao i za zemlje koje već imaju zajedničku valutu (zemlje eurozone) proizlazi iz tri ključna čimbenika koja su omogućena učinkovitim i dobro razvijenim financijskim tržištima:

- Učinkovita alokacija resursa – u konačnici omogućava veće stope rasta i postizanje realne konvergencije s razvijenijim zemljama;
- Podjela rizika – mehanizam koji je neophodan za apsorpciju idiosinkratskih šokova i stabilnost valutnog područja;
- Glatka transmisija monetarne politike – putem financijskih tržišta omogućena je učinkovita i glatka transmisija impulsa monetarne politike.

U nastavku je objašnjena učinkovita alokacija resursa i podjela rizika jer su ti čimbenici važni u kontekstu problema i predmeta ove disertacije.

3.3.1. Učinkovita alokacija resursa

Prema klasičnom gledištu, ekonomski rast može se temeljiti na promjenama u obujmu faktora proizvodnje (rada i kapitala) ili na promjeni učinkovitosti kojom se faktori proizvodnje koriste. U tom kontekstu, financijska integracija može potaknuti veće stope rasta povećanjem kapitala (kao faktora proizvodnje) ili povećanjem učinkovitosti korištenja kapitala

Financijske frikcije povezane s financijskom nerazvijenošću mogu imati dva učinka na akumulaciju kapitala. S jedne strane, kreditno ograničena poduzeća mogu imati vrlo visoke granične stope povrata na investicije i stoga snažnu inicijativu za akumulacijom kapitala. S druge

[22] Naime, pristupanjem EU-u zemlje su se obvezale prihvatiti euro (osim onih zemalja koje imaju option-out klauzulu)

strane, nerazvijeni financijski sektor može smanjiti ponudu kredita i/ili ne može usmjeriti kredite prema najproduktivnijim sektorima. Smanjenjem financijskih frikcija koje ograničavaju privlačenje kapitala u produktivne sektore, financijski razvoj može smanjiti stupanj pogrešne raspodjele (engl. missalocation) kapitala u ekonomiji (Marconi i Upper, 2017).

Međutim, iako razvijeniji financijski sustav pogoduje rastu, to ne znači da je intenzivnije financiranje uvijek dobro. Marconi i Upper (2017) ističu da neželjeni učinci kreditnog rasta na pogrešnu raspodjelu resursa mogu nastati iz nekoliko razloga. Npr., kreditni bumovi mogu pomaknuti investicije prema projektima koji se lakše financiraju, ali istiskuju produktivnije (i rizičnije) projekte. Također, mogu smanjiti poticaj za ulaskom u projekte ili izlaskom iz projekata.

Cecchetti i Kharroubi (2017) na uzorku razvijenih zemalja potvrđuju da se output po radniku smanjuje ako krediti rastu iznad određenog praga, posebno u industrijama s visokim izdacima za istraživanje i razvoj ili s velikim nematerijalnim sredstvima.

Slično tome, veliki priljev kapitala u Portugal nakon preuzimanja eura rezultirao je brzim rastom nerazmjenjivog sektora (Reis, 2013) i smanjenim izlaskom poduzeća s niskom produktivnošću (Dias i ostali, 2016), dva čimbenika koji pomažu objasniti loše rezultate portugalskog gospodarstva u prije pojave globalne financijske krize.

Gopinath i ostali (2017) ističu da je pad realnih kamatnih stopa nakon preuzimanja eura u Španjolskoj povećao disperziju povrata na kapital između poduzeća, što je jasan znak pogrešne raspodjele kapitala. Općenitije gledajući, Borio i ostali (2015) na uzorku razvijenih zemalja potvrđuju da je snažni kreditni rast povezan s neučinkovitom raspodjelom rada među sektorima koja može imati dugotrajne učinke, osobito kada kreditni bum završi financijskom krizom.

Marconi i Upper (2017) potvrđuju da razvijeniji financijski sustavi kvalitetnije usmjeravaju kapital u proizvodne sektore od onih financijskih sustava koji su manje razvijeni. U zemljama s nerazvijenim financijskim sustavima porast akumulacije kapitala obično je povezan sa smanjenjem alokativne učinkovitosti. Međutim, u zemljama s razvijenijim financijskim sustavima taj učinak se okreće i veća ulaganja su u skladu s boljom raspodjelom resursa, što implicira da su financijska tržišta i institucije ključne za usmjeravanje ulaganja prema produktivnijim sektorima.

Dakle, iako je financijska integracija bitna za ostvarenje ekonomskog rasta, snažni priljevi kapitala, pogotovo u zemlje s nerazvijenijim financijskim sustavima, mogu stvoriti probleme u vidu pogrešne raspodjele sredstva koja dugoročno može uzrokovati smanjene stope rasta.

3.3.2. Podjela rizika i uglađivanje potrošnje

Stabilnost valutnog područja ovisi o njegovom kapacitetu da se nosi s idiosinkratskim šokovima koji pogađaju zemlje članice u situaciji kad nisu raspoložive njihove autonomne monetarne politike. Rigidnost cijena i plaća te ograničena mobilnost rada dodatno smanjuju mogućnost zemalja za prilagodbu na idiosinkratske šokove (Furceri i Zdzienicka, 2015). U tom kontekstu, postojanje mehanizama podjele rizika esencijalno je za funkcioniranje valutnih područja. Baele i ostali (2004) ističu da upravo financijska integracija osigurava dodatne mogućnosti zaštite od idiosinkratskih šokova putem tržišnih mehanizama podjele rizika.

Cimadomo i ostali (2018) ističu da se otpornost valutnog područja na ekonomske šokove može povećati učinkovitijom prekograničnom podjelom rizika. Koncept međunarodne podjele rizika općenito se odnosi na ideju da zemlje ili ekonomski agenti (npr. kućanstva ili poduzeća) „podijele rizik“ da bi se osigurali od negativnih događaja koji utječu na njihove ekonomije.

Ekonomska literatura ističe da neočekivane promjene u dohotku i potrošnji (tzv. šokovi) ugrožavaju blagostanje ekonomije. Ekonomski agenti mogu profitirati osiguranjem od takvih događaja putem dva osnovna tipa mehanizama: privatnog (tržišnog) i javnog mehanizma. Privatni mehanizmi podjele rizika djeluju putem dva glavna kanala: kanala štednje (tzv. kreditni kanal) i kanala tržišta kapitala (tzv. kapitalni kanal) (Cimadomo i ostali, 2018).

Asdrubali, Sorensen i Yosha (1996) ističu tri kanala putem kojih se realizira međunarodna podjela rizika:

- zemlje mogu podijeliti rizik putem ukriženog vlasništva proizvodne imovine na razvijenom tržištu kapitala (diversifikacija portfelja);
- fiskalne institucije omogućavaju uglađivanje dohotka putem porezno-transfernog sustava središnjeg budžeta (npr. smanjivanjem poreza i povećanjem transfera prema zemljama koje su pogođene negativnim šokovima). Cimadomo i ostali (2018) ističu da je ovaj kanal općenito dobro razvijen u starijim federacijama (npr. SAD);

- zemlje mogu ugladiti potrošnju prilagodbom svog imovinskog portfelja, npr. pozajmljivanjem ili zaduživanjem na kreditnim tržištima.

Osnovna razlika između tržišta kapitala i tržišta kredita je u vrsti šokova koje mogu apsorbirati. Tržišta kapitala pružaju osiguranje od privremenih i trajnih šokova. Naime, držeći prava na output iz drugih zemalja, građani uglađuju privremene šokove (npr. kod lošeg usjeva) i trajne šokove (npr. pad prihoda u određenoj industriji).
S druge strane, tržišta kredita uglađuju samo privremene šokove jer vjerovnici u drugim zemljama nerado pozajmljuju zemljama pogođenima šokovima kad očekuju da će ti šokovi potrajati. Osim toga, uglađivanje negativnih šokova putem prodaje imovine je teže kod trajnih šokova jer zahtijeva prodaju većih iznosa (npr. nekretnine) što je skupo i dugotrajno.
Dakle, što je veća postojanost šokova, teže je ugladiti potrošnju ex post pozajmljivanjem na tržištima kredita, jer je veća vjerojatnost da oni koji pozajmljuju neće moći isplatiti kredit. Asdrubali, Sorensen i Yosha (1996) ističu da se visoko postojani šokovi mogu ugladiti putem kupovine vrijednosnica na tržištima kapitala.

Važna konceptualna razlika između uglađivanja putem tržišta kredita i tržišta kapitala je ta da je uglađivanje putem tržišta kapitala rezultat *ex ante* aranžmana, tj. prije pojave šokova, a uglađivanje putem tržišta kredita javlja se ex post, tj. nakon pojave šokova (Asdrubali, Sorensen i Yosha, 1996).

Na uzorku koji obuhvaća zemlje SAD-a (u razdoblju od 1964. do 1990. godine) Asdrubali, Sorensen i Yosha (1996) potvrđuju da 25 posto šokova BDP-a nije osigurano, 39 posto šokova se apsorbira uglađivanjem putem tržišta kapitala, a 23 posto se apsorbira uglađivanjem putem tržišta kredita (ostatak od 13 posto apsorbira se putem fiskalnih transfera).
Slično njima, Cimadomo i ostali (2018) ističu da se u SAD-u 60-80% šokova specifičnih za zemlju ugladi kanalima podjele rizika, pri čemu dominantan utjecaj ima kanal tržišta kapitala. Dodatno, apsorpcija 10-15% šokova specifičnih za zemlje u SAD-u se realizira fiskalnim transferima putem središnjeg budžeta.

Za razliku od SAD-a, institucionalnoj arhitekturi eurozone nedostaje središnji budžet pa je uglađivanje putem fiskalnih transfera (fiskalnog kanala) na razini eurozone zanemarivo. U odsutnosti zajedničkog fiskalnog kapaciteta, šokovi se uglavnom apsorbiraju putem izdavanja nacionalnog nekontigentnog (engl. non-contingent) duga. Iako to predstavlja moćan instrument

uglađivanja potrošnje, dug u suštini nije mehanizam podjele rizika, osim ako se njime ne trguje preko nacionalnih granica (Ferrari i Picco, 2016).

Prihvaćanjem zajedničke valute zemlje eurozone izgubile su mogućnost korištenja monetarne politike za neutraliziranje idiosinkratskih šokova. Ferrari i Picco (2016) ističu da postojanje zajedničke monetarne politike i decentralizirane fiskalne politike stvara značajne tenzije po pitanju apsorpcije nacionalnih idiosinkratskih šokova. Naime, za razliku od zemalja koje imaju vlastitu monetarnu politiku, zemlje eurozone ne mogu apsorbirati idiosinkratske šokove putem monetarne politike, a s druge strane ne primaju transfere iz središnjeg budžeta.

Empirijska literatura potvrđuje da savršena podjela rizika u stvarnom svijetu ne postoji. Naime, rast outputa zemalja koreliraniji je od rasta potrošnje, što teorijski gledano nije karakteristika savršenih tržišta. Ovaj fenomen u makroekonomiji poznat je kao *consumption correlation puzzle* ili kvantitativna anomalija te ukazuje na manjak međunarodne podjele rizika.

Osim toga, apsorpcija šokova putem tržišnih mehanizama, pogotovo putem kreditnog kanala, može biti problematična za vrijeme krize. Furceri i Zdzienicka (2015) na uzorku 15 zemalja eurozone potvrđuju da je udio neapsorbiranih šokova u kriznim vremenima značajno veći nego u normalnim vremenima.

3.4. Mjerenje stupnja financijske integracije

Standardnu mjeru financijske integracije vrlo je teško razviti. Kappler i Sachs (2013) navode da je financijska integracija mnogo mutniji koncept od trgovinske integracije što otežava njezino mjerenje. Izraz "financijska integracija" odnosi se na međunarodnu integraciju različitih financijskih tržišta kao što su novčana tržišta, bankovna tržišta, obveznička, dionička tržišta ili tržišta za ostale oblike međunarodnih investicija, što implicira da se stupanj financijske integracije može razlikovati ovisno o promatranom tržištu.

Eichengreen (2001) ističe da postoji više vrsta financijskih transakcija, a neke zemlje nameću cijeli niz cjenovnih i količinskih kontrola na širokom spektru financijskih transakcija što dovodi do ogromnih poteškoća u mjerenju prekograničnih razlika u prirodi, intenzitetu i učinkovitosti prepreka međunarodnim tokovima kapitala.

Definicija financijske integracije koju navode Baele i ostali (2004) bavi se uglavnom asimetričnim učincima ili preprekama u procesu intermedijacije na različitim područjima. Što su sličniji ovi učinci veći je stupanj financijske integracije. Stoga se njihov okvir za mjerenje financijske integracije fokusira na određivanje pogađaju li postojeće frikcije različite regije asimetrično. Najbolji način za mjerenje trenutnog stupnja financijske integracije bila bi analiza i mjerenje svih postojećih frikcija i prepreka, međutim takvo nešto nemoguće je napraviti. Iz tog razloga za mjerenje stupnja financijske integracije autori koriste ravnotežne cijene jer odražavaju sve informacije koje su na raspolaganju ekonomskim agentima, uključujući i moguće frikcije i prepreke s kojima se agenti suočavaju.

Baele i ostali (2004) ističu tri kategorije mjera financijske integracije:

- Cjenovno orijentirane mjere (engl. price based measures);
- Informacijski orijentirane mjere (engl. news based measures);
- Količinski orijentirane mjere (engl. quantity based measures).

Cjenovno orijentirane mjere diskrepanciju cijena ili povrata na imovinu uzrokovanu zemljopisnim podrijetlom imovine. To predstavlja izravnu provjeru zakona jedne cijene koji mora postojati ako je proces financijske integracije u potpunosti završen. Ako imovina ima dovoljno slične karakteristike onda se može napraviti izravna usporedba cijena ili prinosa. U ostalim slučajevima moraju se uzeti u obzir razlike u sistematičnom riziku (kojeg nije moguće diversificirati) i ostalim važnim karakteristikama. Uzevši u obzir ova razmatranja može se konstruirati niz specifičnih mjera financijske integracije. Presječna disperzija razlike kamatnih stopa ili razlika između povrata na imovinu može se koristiti kao pokazatelj koliko su različiti segmenti tržišta udaljeni od potpune integracije. Slično, beta konvergencija pokazuje kojom se brzinom financijska tržišta integriraju. Dodatno, mjerenje stupnja varijacije prekograničnih cijena ili povrata u odnosu na varijabilnost unutar pojedinih zemalja može ukazati na stupanj financijske integracije na različitim tržištima.

Informacijski orijentirane mjere konstruirane su za razlikovanje informacijskih učinaka od drugih frikcija ili prepreka. U financijski integriranim područjima portfelji bi trebali biti dobro diverzificirani. Dakle, dolazak novih vijesti regionalnog karaktera (nove ekonomske informacije) trebao bi imati mali utjecaj na cijene, dok bi utjecaj globalnih vijesti trebao biti relativno važniji,

tj. imati snažniji utjecaj na cijene. U tom slučaju stupanj sustavnog rizika imovine identičan je u različitim zemljama. U suprotnom, financijsko integriranje nije završeno i lokalne vijesti mogu i dalje utjecati na cijenu imovine.

Količinski orijentirane mjere kvantificiraju učinak frikcija s kojima se suočavaju ponuda i potražnja za investicijskim prilikama (Baele i ostali, 2004). Kod ovakvih mjera obično se koristi statistika koja daje informacije o lakoći pristupa tržištu, kao što su npr. prekogranične aktivnosti. Naravno, ni jedna mjera se ne može koristiti za sva tržišta jer se specifičnosti tržišta i raspoloživost podataka za implementaciju mjere razlikuju između financijskih tržišta. Međutim, temeljni koncept je isti, pokušava se uhvatiti mogući opseg asimetrija.
Dakle, količinski orijentirane mjere izravno mjere efektivnu integraciju oslanjajući se na mjerljivi obujam tržišnog trgovanja. Pretpostavka je da veći obujam međunarodnih financijskih transakcija podrazumijeva veći stupanj efektivne integracije. Ovisno o specifičnom tipu podataka koji se koristi, količinski orijentirane mjere mogu se primijeniti na pojedine zemlje, parove zemalja ili grupe zemalja.

Promatrano u odnosu na zastupljenost drugih determinanti usklađenosti poslovnih ciklusa u empirijskim modelima, a s obzirom na važnost koju ima, financijska integracija poprilično je slabo zastupljena u dosadašnjim empirijskim istraživanjima. Razlog tome je činjenica da se prilikom analize utjecaja financijske integracije na usklađivanje poslovnih ciklusa javljaju dva metodološka problema. Prvo, financijska integracija odnosi se na proces međunarodne integracije različitih financijskih što znači da, ovisno o promatranom financijskom tržištu, može postojati različit stupanj financijske integracije između zemalja. Stoga bi bilo pogrešno osloniti se na mjeru financijske integracije koja se odnosi na samo jedno od navedenih tržišta, već se prilikom analize stupnja financijske integracije između zemalja u obzir trebaju uzeti različita financijska tržišta. Drugo, nije moguće *a priori* definirati koncept financijske integracije koji bi bio univerzalno primjenjiv u empirijskim istraživanjima o determinantama usklađenosti poslovnih ciklusa između zemalja. Baele i ostali (2004) definiraju integrirana financijska tržišta kao ona tržišta na kojima svi agenti imaju jednaki pristup tržištu, suočavaju se s jedinstvenim skupom pravila i jednako su tretirani kad su aktivni na tržištu. Ovako široka definicija odnosi se na harmonizaciju zakonodavnog, regulatornog i institucionalnog okvira međunarodnih financijskih tržišta, dimenziju koja se može obuhvatiti binarnim varijablama kao što su npr. MMF-ov

indikator objavljen u godišnjem izvješću o deviznim aranžmanima i deviznim restrikcijama (engl. Annual Report on Exchange Arrangements and Exchange Restrictions - AREAER) ili Chinn-Itov indikator (Chinn i Ito, 2008). Međutim, ovakva *de jure* definicija financijske integracije nije baš primjenjiva u empirijskim istraživanjima. Štoviše, ne obuhvaća nužno *de facto* (stvarni) stupanj financijske integracije promatran na različitim tržištima.

Adam i ostali (2002) te Imbs (2006) ističu superiornost mjera financijske integracije koje imaju sljedeće karakteristike:

- izravno su mjerljive;
- bilateralne su (radije nego agregirane između zemalja);
- obuhvaćaju stanje (engl. stocks) radije nego tokove (engl. flows) kapitala.

Kappler i Sachs (2013) zaključuju da je korištenje količinski orijentiranih mjera financijske integracije na nekoliko financijskih tržišta najbolji način za mjerenje stvarnog stupnja financijske integracije između zemalja. Upravo se količinski orijentirane mjere financijske integracije i koriste u najvećem broju istraživanja determinanti usklađenosti poslovnih ciklusa.

Otto, Voss i Wilard (2003) za indikator financijske integracije koriste bilateralne izravne strane investicije, a financijsku integraciju ($IFDI_{ijt}$) mjere na sljedeći način:

$$IFDI_{ijt} = \frac{FDII_{ijt}+FDIO_{ijt}}{Y_{it}+Y_{jt}} \quad ,$$

pri čemu $FDII_{ijt}$ predstavlja stanje dolaznih izravnih stranih investicija zemlje i iz zemlje j u razdoblju t, $FDIO_{ijt}$ predstavlja stanje odlaznih izravnih stranih investicija zemlje i prema zemlji j u razdoblju t, a Y_{it} predstavlja BDP zemlje i u razdoblju t.

Xing i Abbot (2007) koriste isti indikator financijske integracije kao i Otto, Voss i Wilard (2003), pri čemu financijsku integraciju $IFDIW_{ijt}$ mjere udjelom bilateralnih izravnih stranih investicija u ukupnim izravnim stranim investicijama zemalja:

$$IFDIW_{ijt} = \frac{FDII_{ijt}+FDIO_{ijt}}{FDII_{it}+FDIO_{it}+FDII_{jt}+FDIO_{jt}} \quad ,$$

gdje, $FDII_{it}$ predstavlja stanje ukupnih dolaznih izravnih stranih investicija zemlje *i* u razdoblju *t*, a $FDIO_{it}$ predstavlja stanje ukupnih odlaznih izravnih stranih investicija zemlje *i* u razdoblju *t*. Istu mjeru financijske integracije u svom istraživanju koristi i Alimi (2015).

Za indikator financijske integracije Imbs (2004) koriti intenzitet portfeljnih ulaganja, pri čemu financijsku integraciju (IPI_{ijt}) mjeri udjelom bilateralnih portfeljnih ulaganja u bruto domaćim proizvodima zemalja:

$$IPI_{ijt} = \frac{PI_{ijt}+PI_{jit}}{Y_{it}+Y_{jt}} \ ,$$

gdje PI_{ijt} predstavlja portfeljnu imovinu izdanu od strane rezidenata zemlje *i* koja se nalazi u vlasništvu rezidenata zemlje *j* u razdoblju *t*, a Y_{it} predstavlja BDP zemlje *i* u razdoblju *t*.

Podatke o bilateralnim portfeljnim ulaganjima Imbs (2004) preuzima iz CPIS-ove (Coordinated Portfolio Investment Survey) baze podataka. Međunarodni monetarni fond definira portfeljna ulaganja kao prekogranične transakcije i pozicije koje uključuju dugovne i vlasničke vrijednosnice, osim onih koje su uključene u izravne strane investicije i rezervnu imovinu. Iako CPIS-ova baza podataka sadrži podatke o bilateralnim portfeljnim ulaganjima na godišnjoj razini od 2001. godine za veliki broj zemalja, podaci za Hrvatsku nisu dostupni.

Caporale i Giraldi (2016) za indikator financijske integracije koriste kapitalne tokove između dviju zemalja, pri čemu mjeru financijske integracije *(NFA_{ijt})* definiraju na sljedeći način:

$$NFA_{ijt} = \left|\frac{NFA_{it}}{Y_{it}} - \frac{NFA_{jt}}{Y_{jt}}\right| \quad ,$$

gdje Y_{it} predstavlja nominalni bruto domaći proizvod zemlje *i* u razdoblju *t*, a NFA_{ijt} multilateralnu neto poziciju strane imovine zemlje *j* u razdoblju *t*. Neto poziciju strane imovine čini suma neto pozicije duga, kapitala i izravnih stranih investicija.

Logika iza navedene mjere financijske integracije je sljedeća: ako je zemlja *i* vjerovnik s velikom i pozitivnom neto pozicijom strane imovine, a zemlja *j* dužnik s velikom i negativnom neto pozicijom strane imovine, onda vjerojatno postoje financijski tokovi od zemlje *i* prema zemlji *j*. S druge strane, ako su obje zemlje vjerovnici i imaju pozitivnu neto poziciju strane imovine, onda je manje vjerojatno da postoje veliki financijski tokovi između zemalja i vrijednost NFA_{ijt} će biti mala. Slično tome, ako je jedna zemlja neto vjerovnik, a druga neto dužnik, ali su njihove neto pozicije strane imovine relativno male, onda su financijski tokovi između zemalja mali, što se odražava u manjoj vrijednosti NFA_{ijt}.

Za indikator financijske integracije Kappler i Sachs (2013) koriste bilateralni intenzitet pozicije strane imovine (engl. foreign asset holdings) bankovnog sektora kojeg definiraju kao:

$$BI_{ijt} = \frac{B_{ijt}+B_{jit}}{Y_{it}+Y_{jt}} \quad ,$$

pri čemu B_{ijt} predstavlja vrijednost stranih potraživanja (engl. foreign claims) bankovnog sektora zemlje *i* kod bankovnog i nebankovnog sektora zemlje *j* u razdoblju *t*, a Y_{it} predstavlja BDP zemlje *i* u razdoblju *t*.

Podatke su preuzeli iz konsolidirane bankovne statistike Banke za međunarodna poravnavanja (engl. Bank for International Settlements - BIS). Bower i Gullemineau (2006) koriste istu mjeru financijske integracije kao i Kappler i Sachs (2013), pri čemu umjesto bankovnih stanja (engl. stocks) koriste bankovne tokove koje računaju na temelju promjene pozicije strane imovine banaka u određenom vremenskom razdoblju.

Davis (2014) koristi efektivnu mjeru financijske integracije ($FDRR_{ijt}$) koja se temelji na razlici stopa povrata na financijsku imovinu između dviju zemalja, a definira je sljedeći način:

$$FDRR_{ijt} = |r_{it} - r_{jt}| \quad ,$$

gdje r_{it} predstavlja realnu stopu povrata na dionice i obveznice zemlje *i* u razdoblju *t*.

Autorova logika je sljedeća: ako su zemlje *i* i *j* financijski integrirane, onda arbitražni uvjeti zahtijevaju da su realne stope povrata na njihovu imovinu jednake. Stoga je ova mjera financijske integracije mala ako su zemlje financijski integrirane.

Kalemli-Ozcan, Sorensen i Yosha (2003) financijsku integraciju (FRS_{ijt}) mjere stupnjem podjele rizika prihoda i potrošnje između dviju zemalja:

$$FRS_{ijt} = \beta_{it} + B_{jt} \quad ,$$

gdje β_{it} predstavlja mjeru podjele rizika zemlje *i* u razdoblju *t*.

β_{it} je regresijski koeficijent koji uključuje vremesku seriju bruto domaćeg proizvoda zemlje *i* (GDP_{it}) i potrošnje zemlje *i* (C_{it}):

$$\Delta log(GDP_{it}) - \Delta log(C_{it}) = \alpha_t + \beta_{it}\Delta log(GDP_{it}) + \varepsilon_{it} \quad ,$$

pri čemu α_t označava vremenski fiksne efekte i stoga obuhvaća učinak nediversifibilnog agregatnog proizvodnog rizika.

Ako nema podjele rizika (β_{it}=0) fluktuacije BDP-a (GDP_{it}) izravno se prenose na fluktuacije u potrošnji (C_{it}) – do razine određene idiosinkratičnom greškom (ε_{it}). U slučaju savršene podjele rizika (β_{it}=1) fluktuacije BDP-a ne prenose se na fluktuaciju potrošnje – potrošnja je konstantna (opet do razine određene idiosinkratičnom greškom). Integracija u međunarodna financijska tržišta dovodi do ovakve podjele rizika. Dakle, ako je FRS_{ijt} visok, onda su zemlje *i* i *j* visoko integrirane u međunarodni financijski sustav, tj. stupanj financijske integracije među njima je visok.

U skladu s dosadašnjim istraživanjima, a uzimajući u obzir ograničenja pojedinih mjera i dostupnost podataka, u ovoj disertaciji korištene su dvije mjere financijske integracije – količinski orijentirana mjera (FI1) i cjenovno orijentirana mjera (FI3). Količinski orijentirana mjera (FI1) za indikator financijske integracije koristi stanje bilateralnih izravnih stranih investicija između Hrvatske i zemalja Eurozone. Prednosti navedene mjere su izravna mjerljivost, mogućnost mjerenja na bilateralnoj razini (između parova zemlja) i korištenje stanja (a ne tokova) kapitala, što je u skladu s poželjnim svojstvima mjera financijske integracije koja ističu Adam i ostali (2002) te Imbs (2006). Osim toga, u skladu s teorijskim okvirom, putem navedenog indikatora moguće je analizirati utjecaj financijske integracije na usklađivanje poslovnih ciklusa putem kapitalnog kanala. S druge strane, osnovni nedostatak navedene mjere financijske integracije je taj da ne obuhvaća sve oblike kapitala. Naime, podaci o ostalim oblicima kapitala (portfeljna ulaganja i ostala ulaganja) nisu dostupni na bilateralnoj razini za promatrane zemlje. Cjenovno orijentirana mjera (FI3) za indikator financijske integracije koristi realnu stopu povrata na desetogodišnje obveznice zemalja, pri čemu mjeri razliku između navedenih stopa. Na taj način omogućava testiranje zakona jedne cijene što je temeljna implikacija financijski integriranih tržišta. Osim toga, ovom mjerom moguće je analizirati utjecaj financijske integracije na usklađivanje poslovnih ciklusa putem kreditnog kanala.

4. UTJECAJ FINANCIJSKE INTEGRACIJE NA USKLAĐIVANJE POSLOVNIH CIKLUSA

U ovom poglavlju identificirani su i objašnjeni kanali putem kojih financijska integracija utječe na usklađivanje poslovnih ciklusa. Osim izravnih kanala, naglašeno je i djelovanje putem neizravnih kanala koji omogućavaju bolje razumijevanje ovog kompleksnog odnosa. U svrhu modelskog tretiranja odnosa financijske integracije i usklađenosti ciklusa u petom poglavlju, analizirana su dosadašnja istraživanja utjecaja te naglašeni njihovi nedostaci i ograničenja.

4.1. Transmisijski kanali utjecaja financijske integracije na usklađivanje poslovnih ciklusa

Teorijski gledano, utjecaj financijske integracije na usklađivanje poslovnih ciklusa nije jednoznačan jer postoji više transmisijskih kanala koji nisu istog smjera i intenziteta djelovanja. Na slici 11. grafički su prikazani kanali utjecaja financijske integracije na usklađivanje poslovnih ciklusa zemalja.

Snažno teorijsko uporište za objašnjenje utjecaja financijske integracije na usklađivanje poslovnih ciklusa pruža teorija međunarodnih realnih poslovnih ciklusa. Glavna pretpostavka navedene teorije je da u odsustvu velikih financijskih šokova financijska integracija pojačava učinke šokova ukupne faktorske produktivnosti (engl. total factor productivity - TFP). Naime, Backus, Kehoe i Kydland (1992) razvijaju model opće ravnoteže s dvije zemlje i potpunim financijskim tržištima u kojem objašnjavaju mehanizam djelovanja financijske integracije na usklađivanje poslovnih ciklusa. U navedenom modelu zemlja pogođena pozitivnim šokom produktivnosti ostvaruje povećanje graničnog proizvoda rada i kapitala, radnici zamjenjuju dokolicu za rad i zemlja ostvaruje neto priljev kapitala. Negativni šok produktivnosti ima isti učinak jer zemlja koja nije pogođena negativnim šokom ima veće mogućnosti rasta i stoga će kapital biti preusmjeren u nju. Dakle, prema teoriji međunarodnih realnih poslovnih ciklusa financijska integracija pojačava djelovanje šokova ukupne faktorske produktivnosti čime outputi zemalja divergiraju, tj. smanjuje se stupanj usklađenosti njihovih poslovnih ciklusa.

Imbs (2006) naglašava da bi struktura potrošnje između financijski integriranih regija trebala biti usklađenija od outputa iz dva razloga: (i) kapitalni tokovi slijede razliku u povratu što rezultira negativnom korelacijom u outputima; (ii) agenti konzumiraju iz potpuno diversificiranih portfelja što rezultira savršeno koreliranim planovima potrošnje. Međutim, brojna istraživanja potvrđuju da financijski integriranije ekonomije imaju usklađenije poslovne cikluse što nije u skladu s teorijom. Odstupanje teorije od empirijskih istraživanja u literaturi se zove Backus-Kehoe-Kydland consumption correlations puzzle ili "kvantitativna anomalija" i predstavlja jednu od šest glavnih zagonetki u međunarodnoj makroekonomiji.

Calvo i Mendoza (2000) ističu da se uvođenjem financijskih frikcija u teorijske modele ublažava djelovanje šokova ukupne faktorske produktivnosti, a može se i u potpunosti promijeniti smjer utjecaja financijske integracije na usklađivanje poslovnih ciklusa zemalja. Naime, u modelima gdje su prisutni financijski šokovi i TFP šokovi, negativni šokovi ponude kapitala ili financijske frikcije (koje proizlaze iz asimetričnih informacija i moralnog hazarda) mogu generirati zarazu (koja se događa zbog povlačenja kapitala s drugih tržišta od strane ulagača) i na taj način potaknuti usklađivanje poslovnih ciklusa između financijski integriranih zemalja. Brojni autori (Baxter i Crucini, 1995; Kollmann, 1996; Kehoe i Perri, 2002) u teorijskim modelima s nepotpunim tržištima identificiraju pozitivan utjecaj financijske integracije na usklađivanje poslovnih ciklusa.

De Haan, Inklaar i Jong-a-Pin (2008) naglašavaju da financijska integracija potiče usklađivanje poslovnih ciklusa putem učinaka zaraze. Brojna literatura o zarazi potvrđuje da financijska integracija potiče jače prelijevanje makroekonomskih fluktuacija između zemalja (omogućava lakši prijenos financijskih poremećaja i kriza) što utječe na usklađivanje njihovih poslovnih ciklusa (Allen i Gale, 2000; Calvo i Mendoza, 2000; Mendoza i Quadrini, 2010).

Slika 11. Kanali utjecaja financijske integracije na usklađivanje poslovnih ciklusa

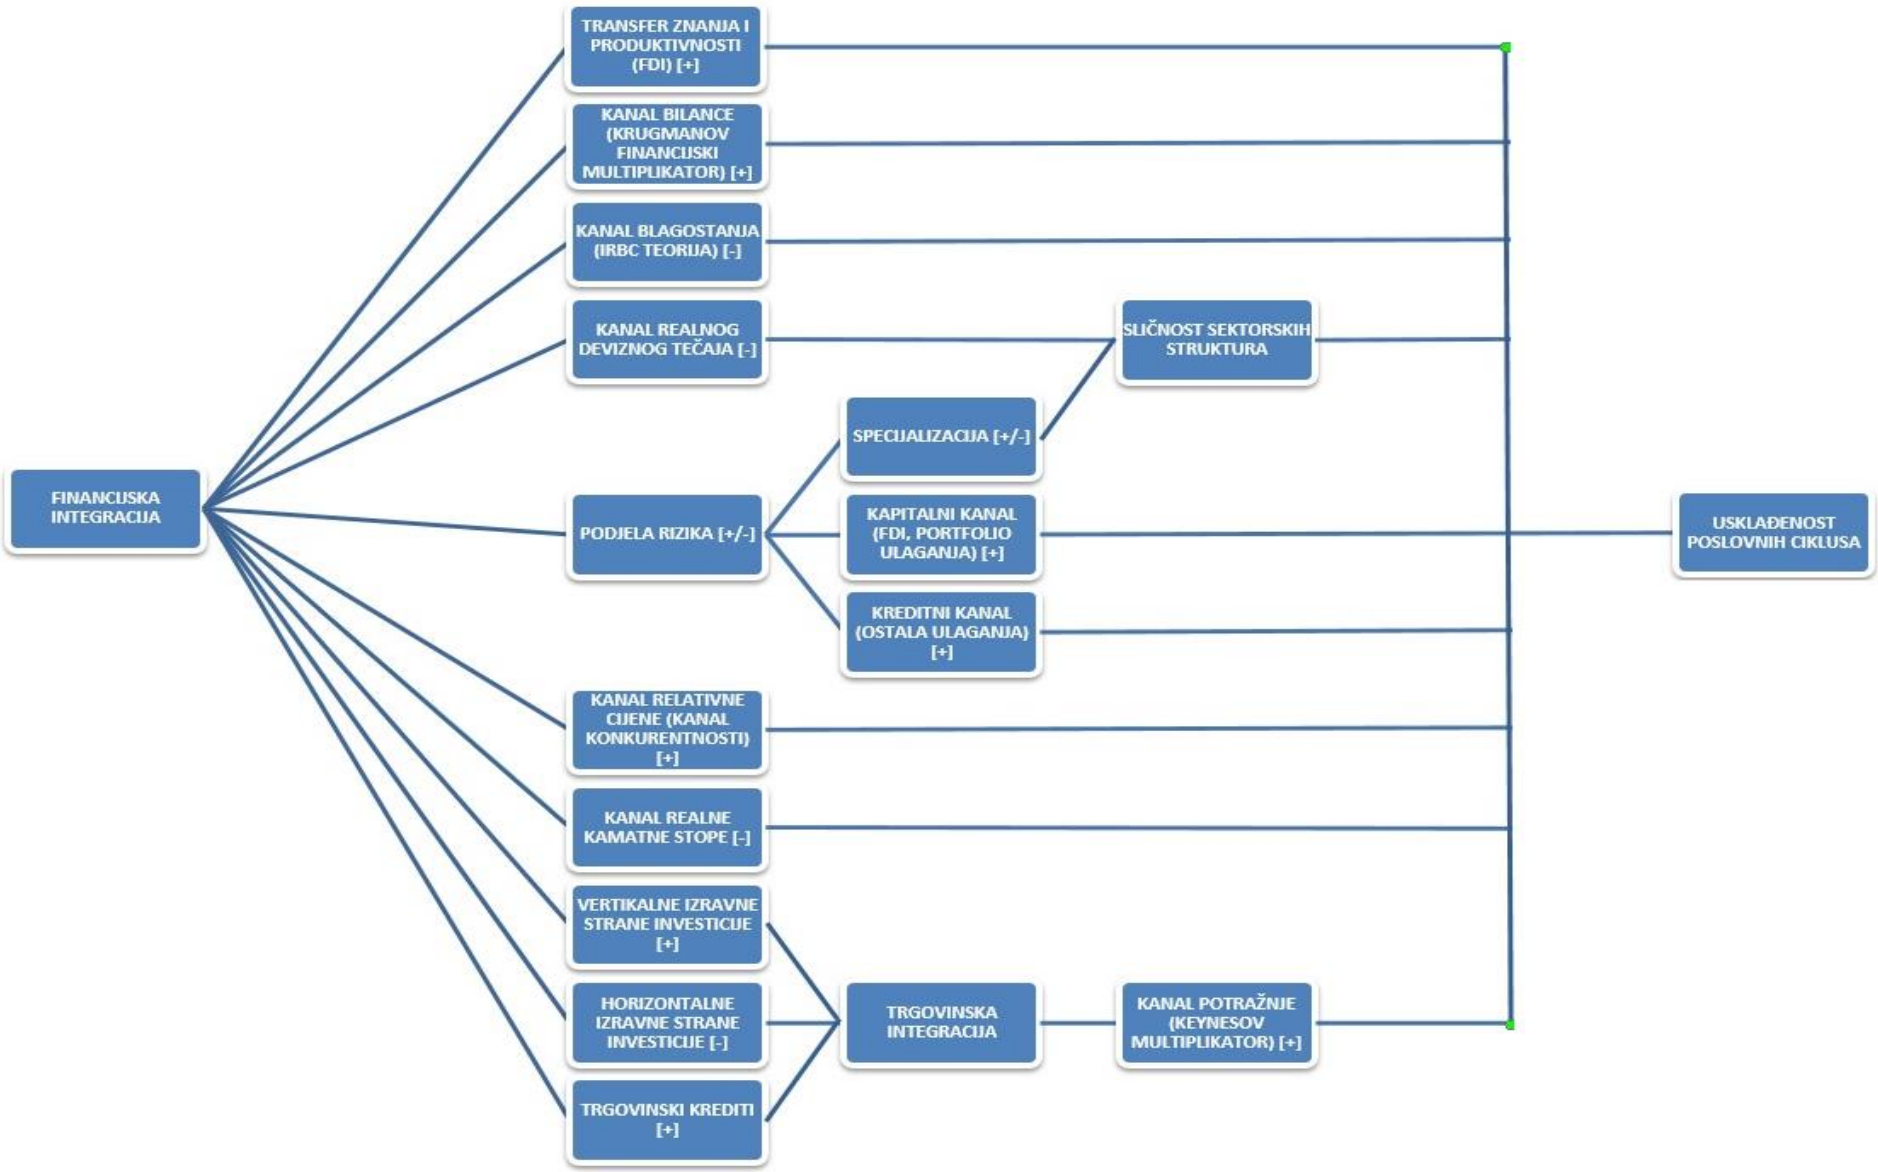

Izvor: Izrada autora

Kalemli-Ozcan, Pappaionnou i Peydro (2013) ističu da teorijska predviđanja o utjecaju financijske integracije[23] na usklađivanje poslovnih ciklusa razlikuju ovise o jačini djelovanja dvije vrste šokova: šokova produktivnosti i financijskih šokova. Kod pojave negativnih šokova produktivnosti dolazi do preusmjeravanja kapitala iz jedne zemlje u drugu što uzrokuje divergenciju outputa zemalja. Naime, ako su poduzeća u određenoj zemlji pogođena negativnim (pozitivnim) šokovima produktivnosti, domaće i strane banke smanjuju (povećavaju) pozajmljivanje u toj zemlji i povećavaju (smanjuju) ga u zemljama koje nisu zahvaćene navedenim šokovima. S druge strane, negativni financijski šokovi, koji se pojavljuju u vrijeme financijskih poremećaja i kriza, uzrokuju smanjenje dostupnosti kapitala u zemljama i time potiču usklađivanje poslovnih ciklusa između financijski integriranih zemalja. Kod pojave negativnog financijskog šoka, banke (koje djeluju globalno) istovremeno povlače sredstva iz svih zemalja što uzrokuje transmisiju domaćeg bankovnog šoka izvan nacionalnih granica i na taj način usklađuju poslovne cikluse zemalja. Neto učinak financijske integracije na usklađivanje poslovnih ciklusa zemalja ovisi o tome koja vrsta šokova dominira.

Slično njima, Morgan, Rime i Strahan (2004) u svom modelu potvrđuju ambivalentan utjecaj bankovne integracije na usklađivanje poslovnih ciklusa zemalja. Naime, u slučaju segmentiranog bankovnog sustava, pad ponude kredita u zemlji A povećava povrate banaka u toj zemlji, ali nema utjecaja na tržište kredita u zemlji B; zajmoprimci u zemlji A snose puni teret negativnog šoka u obliku povećanja kamatnih stopa na zajmove i/ili smanjenja količine kredita. Kod integriranog bankovnog sustava veća stopa povrata na bankovni kapital privlači kredite iz zemlje B u zemlju A što djelomično neutralizira početni utjecaj na ponudu kredita u zemlji A. U slučaju pada potražnje za kreditima (zbog lošeg zdravlja ili pada vrijednosti kolaterala kod zajmoprimaca) bankovna integracija potiče smanjenje investicija olakšavajući protok kredita od zemlje A prema zemlji B. Autori zaključuju da konačni učinak djelovanja bankovne integracije na usklađenost poslovnih ciklusa ovisi o tome koja vrsta šokova dominira.

Davis (2014) ističe da različiti oblici financijske integracije imaju različiti utjecaj na usklađivanje poslovnih ciklusa zemalja. Naime, integracija tržišta kapitala i integracija tržišta kredita djeluju na usklađivanje poslovnih ciklusa putem dvaju različitih učinaka koji imaju suprotan smjer djelovanja – učinka bilance i učinka blagostanja.

[23] Autori u radu pod pojmom financijske integracije podrazumijevaju bankovnu integraciju, tj. fokusiraju se isključivo na međubankovno tržište.

Učinak bilance (engl. balance sheet effect) karakterističan je za integrirano tržište kredita. Ako domaće banke izdaju kredite stranim poduzetnicima, onda će negativni šok u stranoj zemlji (koji uzrokuje pad proizvodnje i povećanje broja stečajeva) utjecati i na bilance domaćih banaka. Naime, suočene s povećanim gubitkom od stranog kreditnog portfelja domaće banke će, osim ponude stranih kredita, smanjiti ponudu kredita prema domaćim zajmoprimcima, što će uzrokovati pad domaće proizvodnje. Ovaj učinak posljedica je djelovanja mehanizma međunarodnog financijskog multiplikatora (eng. international financial multiplier) kojeg opisuje Krugman (2008).

Hsu, Wu i Yau (2011) naglašavaju da kanal bilance može djelovati i putem izravnih stranih investicija na način da se pogoršanjem ekonomskih uvjeta u zemlji davateljici može smanjiti zaposlenost i plaće u zemlji primateljici. Ključnu ulogu u tom procesu ima međunarodna podjela rente (engl. rent sharing) unutar multinacionalnih kompanija koja uzrokuje širenje lokalnih makroekonomskih šokova iz jedne zemlje u drugu.

Učinak blagostanja (engl. wealth effect) karakterističan je za integrirano tržište kapitala i sastavni je dio već navedene teorije realnih poslovnih ciklusa. Ako npr., agenti u zemlji B imaju kapitalna potraživanja prema investicijskim projektima u zemlji A, onda će negativni tehnološki šok u zemlji A uzrokovati pad bogatstva u zemlji B. U uvjetima tržišne ravnoteže (koja podrazumijeva jednakost između potražnje za investicijama i ponude štednje), pod utjecajem negativnog tehnološkog šoka u zemlji A dolazi do pada investicija u zemlji A (tj. pada investicijske potrošnje). Pad bogatstva u zemlji B uzrokovan negativnim tehnološkim šokom u zemlji A, utjecat će na povećanje štednje u zemlji B, što će dalje uzrokovati povećanje investicijske potrošnje u zemlji B. Prema tome, negativni tehnološki šok u zemlji A uzrokuje pad investicija u zemlji A i rast investicija u zemlji B. Dakle, integracija tržišta kapitala smanjuje usklađenost poslovnih ciklusa zemalja (potiče njihovu divergenciju), a integracija tržišta kredita potiče usklađivanje poslovnih ciklusa zemalja.

U slučaju da ne postoje prekogranična kapitalna potraživanja bogatstvo u zemlji B ostalo bi nepromijenjeno pod utjecajem negativnog tehnološkog šoka u zemlji A. Investicije u zemlji A bi opale, ali u zemlji B se ne bi mijenjale. Također, ponuda štednje u zemlji B ne bi se mijenjala. Poslovni ciklusi zemalja A i B divergirali bi pod utjecajem specifičnih šokova, ali ni približno

koliko u slučaju da postoji prekogranično vlasništvo kapitala zbog kojeg šok u jednoj zemlji utječe na bogatstvo agenata u drugoj zemlji. Davis (2014) ističe da učinak bilance ne djeluje na poslovne cikluse isključivo na integriranom tržištu kapitala, niti učinak bogatstva ne djeluje na poslovne cikluse isključivo na integriranom tržištu kredita, već učinak bogatstva dominira nad učinkom bilance na integriranom tržištu kapitala, a učinak bilance dominira nad učinkom bogatstva na integriranom tržištu kredita.

Hsu, Wu i Yau (2011) navode transfer znanja i produktivnosti putem izravnih stranih investicija kao važne transmisijske kanale utjecaja financijske integracije na usklađivanje poslovnih ciklusa između zemalja. Naime, strani ulagači gotovo istovremeno uvode novu tehnologiju na domaće i strana tržišta što uzrokuje istovremene tehnološke impulse koji slično utječu na poslovne cikluse zemalja (Ševela, 2016).

Osim putem transmisije poslovnih ciklusa (šokova), financijska integracija utječe na usklađivanje poslovnih ciklusa apsorpcijom idiosinkratskih šokova putem tržišnog mehanizma podjela rizika. Mundell je naknadno shvatio važnost djelovanja ovog kanala i promijenio koncept promišljanja o prihvaćanju zajedničke valute (fiksiranju tečaja)[24]. Naime, Mundell (1973) naglašava da nesigurnost deviznog tečaja remeti tržište kapitala i onemogućava međunarodnu diversifikaciju portfelja čime smanjuje kapacitet apsorpcije asimetričnih šokova. Zajednička valuta (fiksiranje tečaja) potaknula bi diversifikaciju portfelja, a time omogućila bolju podjelu rizika.

Mehanizam podjele rizika ključan je u arhitekturi valutnih područja i zemalja koje su u procesu monetarnog integriranja (poput Hrvatske). Cimadomo i ostali (2018) ističu dva osnovna kanala mehanizma tržišne podjele rizika: kreditni kanal i kapitalni kanal. Kapitalni kanal djeluje putem tržišta kapitala, a omogućava *ex ante* osiguranje od pojave idiosinkratskih šokova putem ukriženog prava vlasništva na imovinu, kamatu i rentu. Dakle, kapitalni kanal prvenstveno se vezuje uz izravna strana ulaganja i portfeljna ulaganja, pri čemu izravna strana ulaganja zbog karaktera ulaganja imaju značajniju ulogu[25]. S druge strane, kreditni kanal omogućava *ex post*

[24] U literaturi se često spominje Mundell I protiv Mundella II. Detaljnije o ovome pogledati u Mckinnon (2004).
[25] Po definiciji izravnih stranih ulaganja strani investitor stječe trajni interes u poduzeću primatelju stranog ulaganja što implicira dugoročni odnos između investitora i primatelja investicije. Kod portfeljnih ulaganja ključna je očekivana zarada zbog čega je za takav oblik ulaganja karakteristična česta promjena mjesta ulaganja.

prilagodbu na idiosinkratske šokove putem zaduživanja/pozajmljivanja na tržištu kredita. Česta kritika kreditnog kanala je njegova neučinkovitost kod pojave snažnih negativnih šokova, a upravo je to situacija u kojoj bi njegovo djelovanje trebalo biti izraženo.

Ruscher (2015) naglašava još dva mehanizma putem kojih financijska integracije utječe na apsorpciju asimetričnih šokova, a time i na usklađenost poslovnih ciklusa: mehanizam relativne cijene (engl. relative price mechanism) i mehanizam realne kamatne stope (engl. real interest rate mechanism).

Promjene relativnih cijena predstavljaju važan mehanizam putem kojeg se zemlje eurozone prilagođavaju na asimetrične šokove. Naime, kod zemalja članica sa slabijom cikličkom pozicijom od ostatka unije troškovi rada i cijene opadaju u odnosu na ostatak unije. Posljedično poboljšanje realnog efektivnog deviznog tečaja pomaže ojačati cikličku poziciju zemalja putem učinaka na izvoz i supstituciju uvoza. Kanal relativne cijene se zbog mehanizma djelovanja često zove i kanal konkurentnosti (engl. competitiveness channel).

Kanal realne kamatne stope predstavlja mehanizam koji djeluje destabilizirajuće na valutno područje, tj. smanjuje usklađenost poslovnih ciklusa. Promjene relativnih cijena u valutnom području utječu na realne kamatne stope. Tako npr., kod zemalja članica koje ostvaruju snažni porast potražnje inflacija raste u odnosu na ostatak valutnog područja. S obzirom na zajedničku nominalnu kamatnu stopu, viša inflacija implicira nižu realnu kamatnu stopu koja dodatno pojačava potražnju. Ovaj mehanizam poznat je kao „Waltersova kritika“.
Ruscher (2015) navodi da su u pojedinim zemljama eurozone niže realne kamatne stope potaknule kreditni rast koji je pojačao privatnu potrošnju i generirao deficite tekućeg računa bilanci plaćanja. S druge strane, realne kamatne stope kod zemalja s nižom inflacijom ograničile su domaću potražnju i dovele do stvaranja suficita tekućeg računa bilanci plaćanja. Iako Hrvatska još nije članica eurozone, male fluktuacije deviznog tečaja omogućavaju djelovanje ovog mehanizma.

Obstfeld (1994) razvija stohastički model s više zemalja u kojem formalizira još jedan mehanizam kojim financijska integracija negativno utječe na usklađivanje poslovnih ciklusa. Naime, u navedenom modelu financijska integracija pomiče investicije prema rizičnijim projektima što omogućava zemljama da se specijaliziraju u skladu sa svojim komparativnim prednostima. Brojni

teorijski modeli također potvrđuju da financijska integracija inducira specijalizaciju u proizvodnji (Saint-Paul, 1992; Acemoglu i Zilibotti, 1997; Feeney, 1999) i sl.). Viši stupanj specijalizacije implicira negativnu korelaciju stopa rasta između financijski integriranih zemalja jer zemlje postaju osjetljivije na pojavu idiosinkratskih šokova.

S druge strane, zemlje se mogu specijalizirati u istim proizvodnim sektorima u situaciji kad se izravne strane investicije koncentriraju u sektorima u kojima zemlja domaćin ima komparativne prednosti, replicirajući na taj način svoju proizvodnu strukturu u drugoj zemlji (Garcia-Herrero i Ruiz, 2008). U tom slučaju slične proizvodne strukture zemalja pozitivno utječu na usklađivanje njihovih poslovnih ciklusa jer su takve zemlje (koje proizvode istu vrstu proizvoda) izložene sličnim šokovima (Dees i Zorel, 2012).

Financijska integracija utječe na sektorsku strukturu i putem kanala realnog deviznog tečaja, pri čemu ključnu ulogu u snazi navedenog kanala ima prvenstveno struktura kapitala. Naime, Davis (2015) naglašava da egzogeno povećanje dugovnog kapitala potiče aprecijaciju realnog deviznog tečaja, dok vlasnički kapital gotovo da i nema utjecaja. Aprecijacija realnog deviznog tečaja pogoršava konkurentnost razmjenjivog sektora što u konačnici doprinosi koncentraciji kapitalnih priljeva u nerazmjenjivim sektorima (Giavazzi i Spaventa, 2010). U takvoj situaciji dolazi do promjene sektorskih struktura zemalja, tj. njihove specijalizacije. Ovakav oblik specijalizacije smanjuje potencijal rasta zemlje koja ostvaruje snažni priljev kapitala i otežava njezinu realnu konvergenciju s razvijenijim zemljama. Također, na taj način smanjuje se usklađenost poslovnih ciklusa promatranih zemalja. Dakle, kanal realnog deviznog tečaja djeluje putem dužničkog kapitala.

Literatura ističe još jedan neizravni kanal utjecaja financijske integracije na usklađivanje poslovnih ciklusa – kanal trgovinske integracije. Trgovinska integracija generira učinke na strani potražnje (Keynesov multiplikator), tj. utječe na jače prelijevanje šokova potražnje iz jedne zemlje i na taj način potiče usklađivanje njihovih poslovnih ciklusa.

Utjecaj financijske integracije na trgovinsku integraciju realizira se putem tri osnovna transmisijska kanala: vertikalnih izravnih stranih investicija, horizontalnih izravnih stranih investicija i trgovinskih kredita. Vertikalne izravne strane investicije omogućavaju multinacionalnim kompanijama razdvajanje poslovnih aktivnosti prema fazama proizvodnog

procesa iskorištavajući na taj način komparativne (troškovne) prednosti zemalja (Helpman, 1984). Kao takve predstavljaju komplement trgovini i potiču trgovinsku integraciju zemalja. Horizontalne izravne strane investicije se pojavljuju kad postoje sličnosti u veličini tržišta i raspoloživosti faktora proizvodnje, a ostvaruju uštede na troškovima izvoza, osiguravaju kraće vrijeme isporuke i blizinu tržišta koja omogućava bržu prilagodbu i udovoljavanje zahtjevima potrošača. Markusen i Venables (2000) ističu da horizontalne izravne investicije predstavljaju zamjenu za postojeće trgovinske tokove što implicira njihov negativan utjecaj na trgovinsku integraciju. Kanal trgovinskih kredita posljedica je oslanjanja međunarodne trgovine na trgovinske kredite. Veći stupanj financijske integracije smanjuje troškove trgovinskih kredita i time potiče međunarodnu trgovinu. Dakle, teorijski gledano utjecaj financijske integracije na usklađivanje poslovnih ciklusa putem kanala trgovinske integracije nije jednoznačan.

U tablici 1. dat je sumarni prikaz kanala utjecaja financijske integracije na usklađivanje poslovnih ciklusa s kratkim opisom mehanizma djelovanja, očekivanim utjecajem i oblikom kapitala putem kojeg se realizira.

Tablica 1. Sumarni prikaz kanal utjecaja financijske integracije na usklađivanje poslovnih ciklusa

Naziv kanala	Mehanizam djelovanja	Očekivani utjecaj na usklađivanje poslovnih ciklusa	Oblik kapitala putem kojeg se realizira
Transfer znanja i produktivnosti	Putem FDI dolazi do transfera znanja i produktivnosti koji slično utječu na poslovne cikluse	Pozitivan [+]	FDI
Kanal bilance	Preljevanje šokova putem FDI i bilanci banaka	Pozitivan [+]	FDI, Ostala ulaganja
Kanal blagostanja	Mobilni kapital seli prema područjima s većim povratom (pojačava djelovanja TFP šokova)	Negativan [-]	FDI, potfeljna ulaganja, ostala ulaganja
Kanal realnog deviznog tečaja	Aprecijacija realnog deviznog tečaja pogoršava konkurentost razmjenjivog sektora i doprinosi koncentraciji kapitala u nerazmjenjivim sektorima	Negativan [-]	Ostala ulaganja
Kanal specijalizacije	Pomicanje investicija prema rizičnijim projektima što omogućava zemljama da se specijaliziraju u skladu s komparativnim prednostima	Pozitivan [+] / Negativan [-]	FDI, potfeljna ulaganja, ostala ulaganja
Kapitalni kanal	*Ex ante* prilagodba na idiosinkratske šokove	Pozitivan [+]	FDI, portfeljna ulaganja
Kreditni kanal	*Ex post* prilagodba na idiosinkratske šokove	Pozitivan [+]	Ostala ulaganja
Kanal relativne cijene	Putem relativnih cijena utječe na konkuretnost, tj, na izvoz i substituciju uvoza	Pozitivan [+]	Ostala ulaganja
Kanal realne kamatne stope	Zajednička nominalna kamatna stopa implicira različitu realnu kamatnu stopu koja dodatno pojačava/slabi potražnju	Negativan [-]	Ostala ulaganja
Kanal vertikalnih izravnih stranih investicija	Putem vertikalnih FDI potiče trgovinsku integraciju koja generira učinke na strani potražnje	Pozitivan [+]	FDI
Kanal horizontalnih izravnih stranih investicija	Horizontalne FDI predstavljaju zamjenu za trgovinske tijekove čime slabe djelovanje učinka na strani potražnje	Negativan [-]	FDI
Kanal trgovinskih kredita	Trgovinski krediti potiču trgovinsku integraciju koja generira učinke na strani potražnje	Pozitivan [+]	Ostala ulaganja

Izvor: Izrada autora

Očigledno je da financijska integracija utječe na usklađivanje poslovnih ciklusa putem nekoliko izravnih i neizravnih kanala čiji se mehanizam djelovanja realizira kroz različite oblika kapitala. Identifikacija kanala i poznavanje mehanizama njihovog djelovanja važno je radi objašnjenja

ovog kompleksnog odnosa, a pomaže u analizi troškova monetarnog integriranja i daje implikacije za vođenje makroekonomske politike.

4.2. Pregled istraživanja utjecaja financijske integracije na usklađivanje poslovnih ciklusa

Dosadašnja istraživanja potvrđuju teorijsku ambivalentnost utjecaja financijske integracije na usklađivanje poslovnih ciklusa zemalja. Naime, smjer i intenzitet utjecaja u dosadašnjim radovima primarno ovisi o izabranim indikatorima financijske integracije, načinu mjerenja usklađenosti poslovnih ciklusa, promatranom vremenskom razdoblju i korištenom uzorku zemalja.

Kose, Prasad i Terones (2003) provode empirijsku analizu baziranu na godišnjim podacima u razdoblju od 1960. do 1999. godine na uzorku od 76 zemalja (21 industrijska i 55 u razvoju) i zaključuju da financijska integracija (mjerena restrikcijama na transakcije kapitalnog računa i akumuliranim bruto kapitalnim tokovima) pojačava globalna prelijevanja makroekonomskih fluktuacija i na taj način povećava stupanj usklađenosti poslovnih ciklusa između zemalja.

Imbs (2004) istražuje utjecaj financijskih poveznica na usklađivanje poslovnih ciklusa. Promatrajući 24 većinom razvijene zemlje u razdoblju od 1980. do 2000. godine zaključuje da financijska integracija promovira usklađivanje poslovnih ciklusa zemalja. Također, nalazi i neizravan utjecaj financijske integracije na specijalizaciju koji vodi smanjenju usklađenosti poslovnih ciklusa. Naglašava da izravni učinci financijske integracije na usklađivanje poslovnih ciklusa dominiraju nad neizravnim učincima.

Utjecaj financijske integracije na usklađivanje poslovnih ciklusa 15 OECD zemalja u razdoblju od 1984. do 2003. godine analiziraju Xing i Abbott (2007). Autori zaključuju da financijska integracija ima negativan utjecaj na usklađivanje poslovnih ciklusa zemalja. Osim toga, financijska integracija utječe na usklađivanje poslovnih ciklusa i neizravno putem trgovinske integracije te specijalizacije.

Garcia-Herrero i Ruiz (2008) analiziraju utjecaj financijske integracije na usklađivanje poslovnih ciklusa Španjolske (kao benchmark zemlje) i zemalja EU, G7 te zemalja Latinske Amerike

(ukupno 109 zemalja). Koristeći bilateralne financijske tokove za mjerenje financijske integracije pokazuju da financijska integracija negativno utječe na usklađivanje poslovnih ciklusa između Španjolske i navedenih zemalja. Zaključuju da financijska integracija potiče lakši transfer sredstava koji omogućava divergenciju poslovnih ciklusa zemalja što je i predviđeno standardnim modelom međunarodnih poslovnih ciklusa.

Na uzorku od 51 zemlje (od čega 27 tržišta u razvoju) u razdoblju od 1970. do 2008. godine Akin (2012) pronalazi da financijska integracija nema značajan utjecaj na usklađivanje poslovnih ciklusa zemalja. Dodatno, identificira slabi utjecaj financijske integracije koji, kod parova razvijenih zemalja te kod parova razvijenih i zemalja u razvoju, smanjuje usklađenost poslovnih ciklusa, dok kod parova zemalja u razvoju povećava usklađenost poslovnih ciklusa.

Analizirajući utjecaj financijske integracije na usklađivanje poslovnih ciklusa na uzorku od 18 bogatih ekonomija (Australija, Austrija, Belgija, Kanada, Švicarska, Njemačka, Danska, Španjolska, Finska, Francuska, Ujedinjeno Kraljevstvo, Irska, Italija, Japan, Nizozemska, Portugal, Švedska i SAD) u razdoblju od 1978. do 2007. godine, Kalemli-Ozcan, Papaioannou i Peydro (2013) potvrđuju da jače financijske poveznice negativno djeluju na usklađivanje njihovih poslovnih ciklusa. Ističu da u promatranom razdoblju djeluju šokovi produktivnosti te da je potrebno napraviti daljnja empirijska istraživanja kako bi se utvrdio utjecaj financijske integracije na usklađenost poslovnih ciklusa u razdoblju nakon 2007. u kojem dolazi do financijske krize i dominacije financijskih šokova.

Antonakakis i Tondl (2014) zaključuju da financijska integracija (mjerena udjelom FDI-a parova zemalja u odnosu na sumu njihovih BDP-a) ima pozitivan neto učinak na usklađivanje poslovnih ciklusa između zemalja EU u razdoblju od 1995. do 2012. godine. Posebno jak utjecaj financijske integracije na usklađenost poslovnih ciklusa postoji između parova zemalja koje uključuju nove i stare EU članice. Pozitivno djelovanje povezuju s vertikalnim FDI kod kojih su različite faze proizvodnje locirane na različitim mjestima u EU slijedeći pri tome komparativne prednosti. Dalje, osim vertikalnih FDI-a ističu još jedan oblik izravnih stranih investicija – investicije zbog osvajanja novih tržišta (engl. market seeking FDI), koje traže prinos i diversifikaciju rizika na

tržištima s različitim stopama rasta i na taj način djeluju negativno na usklađivanje poslovnih ciklusa zemalja.

Konačno, Dees i Zorell (2012) na uzorku 56 zemalja u razdoblju od 1993. do 2007. godine potvrđuju da financijska integracija nema značajan utjecaj na usklađivanje poslovnih ciklusa, a do istih rezultata za mediteranske zemlje (Egipat, Maroko, Tunis i Turska) u odnosu na njihove glavne europske partnere (Njemačka, Francuska i Italija) u razdoblju od 1980. do 2007. godine dolazi Alimi (2015).

Većina prikazanih istraživanja obuhvaća razdoblje prije krize u kojem negativni utjecaji financijske integracije (a time i manjkavosti koncepta financijske integracije) na usklađivanje poslovnih ciklusa nisu bili toliko izraženi. Dalje, u istraživanjima je većinom korištena presječna (engl. cross section) analiza koja gotovo u potpunosti zanemaruje vremensku komponentu. S obzirom na to da financijska integracija i usklađenost poslovnih ciklusa imaju vlastitu dinamiku, očigledna je manjkavost pristupa kojim se uglađuju vrijednosti kroz dulje vremensko razdoblje. Osim toga, u istraživanjima su naglašeni izravni kanali utjecaja financijske integracije koji se većinom odnose na transmisiju poslovnih ciklusa, iako teorija ističe važnost mehanizma podjele rizika (kreditnog i kapitalnog kanala) za usklađivanje poslovnih ciklusa. Također, utjecaj putem neizravnih kanala (specijalizacije i trgovinske integracije) nije dovoljno naglašen, a može imati značajnu ulogu u procesu (ne)usklađivanja poslovnih ciklusa.

5. EMPIRIJSKA ANALIZA UTJECAJA FINANCIJSKE INTEGRACIJE NA USKLAĐIVANJE POSLOVNOG CIKLUSA HRVATSKE SA ZEMLJAMA EUROZONE

U ovom poglavlju analizira se smjer i intenzitet utjecaja različitih izravnih i neizravnih kanala financijske integracije na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone provođenjem ekonometrijske analize. U prvom potpoglavlju kreiran je empirijski model istraživanja. Korištene varijable i indikatori prikazani su u drugom potpoglavlju, a uzorak je definiran u trećem potpoglavlju. Konačno, ekonometrijska analiza utjecaja prikazana je u četvrtom potpoglavlju.

5.1. Empirijski model istraživanja

U skladu s teorijskim okvirom, a na temelju dosadašnjih empirijskih istraživanja, definiran je empirijski model utjecaja financijske integracije na usklađivanje poslovnih ciklusa (prikazan na slici 12). Usklađenost poslovnih ciklusa, osim putem financijske integracije, objašnjena je pomoću tri varijable: trgovinske integracije, konvergencije fiskalnih politika i sličnosti sektorskih struktura.

Iako teorija optimalnih valutnih područja ističe fleksibilnost cijena i plaća kao važne mehanizme stabilizacije poslovnih ciklusa zemalja, varijable fleksibilnost cijena i fleksibilnost plaća nisu uključene u empirijski model zbog nedostupnosti podataka.

Dodatno, varijabla monetarne politike nije uključena u model uz sljedeće objašnjenje. Naime, Hrvatska ima upravljano fluktuirajući devizni režim u kojem tečaj kune prema euru u duljem vremenskom razdoblju fluktuira u okviru svega nekoliko postotaka[26]. Stoga nije realno za očekivati da se takve minimalne fluktuacije nominalnog tečaja značajno odražavaju na dinamiku poslovnih ciklusa promatranih zemalja.

[26] Hrvatska narodna banka odabrala je stabilnost tečaja kune prema euru kao nominalno sidro monetarne politike

Utjecaj financijske integracije na usklađivanje poslovnih ciklusa može se prikazati sljedećom jednadžbom:

$$\rho_{ijt} = \alpha_0 + \alpha_1 KFP_{ijt} + \alpha_2 TI_{ijt} + \alpha_3 FI_{ijt} + \alpha_4 SS_{ijt} + \mu_{ijt} \quad ,$$

gdje ρ_{ijt} predstavlja usklađenost poslovnih ciklusa, FI_{ijt} financijsku integraciju, TI_{ijt} trgovinsku integraciju, SS_{ijt} sličnost sektorskih struktura, a KFP_{ijt} konvergenciju fiskalnih politika zemalja.

Slika 12. Empirijski model utjecaja financijske integracije na usklađivanje poslovnih ciklusa

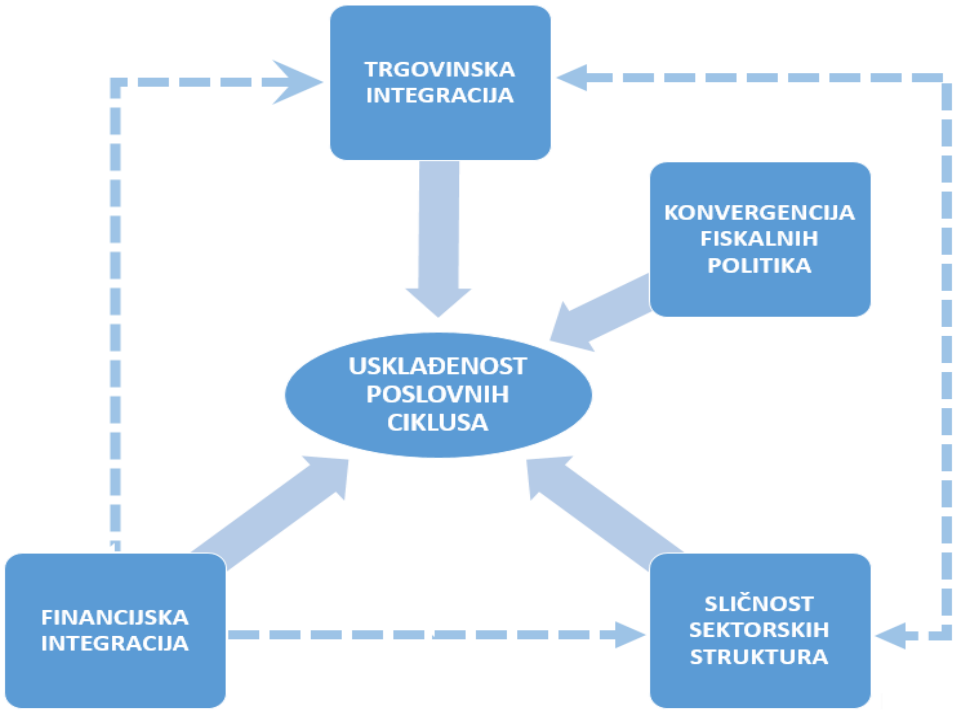

Izvor: Izrada autora

S obzirom na to da sektorska struktura zemalja utječe na usklađivanje njihovih poslovnih ciklusa, dio utjecaja financijske integracije na usklađivanje poslovnih ciklusa realizira se neizravno putem utjecaja financijske integracije na sektorske strukture zemalja (sličnost sektorskih struktura), što je i vidljivo sa slike 12.

Sličnost sektorskih struktura u empirijskom modelu objašnjena je pomoću financijske integracije, trgovinske integracije, veličine zemalja i stupnja razvijenosti zemalja, a navedeni utjecaj može se prikazati sljedećom jednadžbom:

$$SS_{ijt} = \beta_0 + \beta_1 TI_{ijt} + \beta_2 FI_{ijt} + \beta_3 VZ_{ijt} + \beta_4 RZ_{ijt} + \mu_{ijt} \quad ,$$

gdje VZ_{ijt} predstavlja veličinu zemalja, a RZ_{ijt} stupanj razvijenosti zemalja.

Dodatno, uzimajući u obzir da trgovinska integracija utječe na usklađivanje poslovnih ciklusa zemalja, dio utjecaja financijske integracije na usklađivanje poslovnih ciklusa realizira se neizravno putem utjecaja financijske integracije na trgovinsku integraciju. U empirijskom modelu trgovinska integracija objašnjena je pomoću financijske integracije, sličnosti sektorskih struktura, veličine zemalja i stupnja razvijenosti zemalja, a navedeni utjecaj može se prikazati sljedećom jednadžbom:

$$TI_{ijt} = \gamma_0 + \gamma_1 FI_{ijt} + \gamma_2 SS_{ij} + \gamma_3 VZ_{ijt} + \gamma_4 RZ_{ijt} + \mu_{ijt} \quad ,$$

Očekivani predznak parametra α_1 nije jednoznačan. S jedne strane, ako fiskalne politike zemalja imaju stabilizacijsku funkciju (anticiklička fiskalna politika), kod pojave idiosinkratskih šokova divergencija fiskalnih politika povezana je s većim stupnjem usklađenosti poslovnih ciklusa i predznak parametra α_1 je negativan. S druge strane, ako su šokovi fiskalne politike izvor poslovnih ciklusa zemalja (prociklička fiskalna politika), konvergencija fiskalnih politika zemalja vodi ka većoj usklađenosti njihovih poslovnih ciklusa i predznak parametra α_1 je pozitivan.

Utjecaj trgovinske integracije na usklađivanje poslovnih ciklusa također nije jednoznačan. Naime, trgovinska integracija generira učinke na strani potražnje (Keynesov multiplikator), tj. utječe na jače prelijevanje šokova potražnje iz jedne zemlje u drugu i time potiče usklađivanje poslovnih ciklusa zemalja. Međutim, ako su industrijski specifični šokovi dominantni čimbenik generiranja cikličkog outputa, trgovinska integracija potaknut će divergenciju poslovnih ciklusa zemalja kod kojih je većina trgovine inter-industrijskog tipa. U skladu s navedenim, očekivani predznak parametra α_2 nije jednoznačan.

Prema teoriji međunarodnih realnih poslovnih ciklusa (Backus, Kehoe i Kydland, 1992) visoko mobilni kapital kreće se iz jedne zemlje u drugu loveći pritom najveći povrat. Na taj način pojačava djelovanje šokova ukupne faktorske produktivnosti i smanjuje usklađenost poslovnih ciklusa zemalja. S druge strane, financijska integracija putem mehanizma međunarodnog financijskog multiplikatora (Krugman, 2008), koji djeluje preko bilanci banaka i multinacionalnih poduzeća, potiče usklađivanje poslovnih ciklusa zemalja. U skladu s navedenim očekivani predznak parametra α_3 nije jednoznačan.

Očekivani predznak parametra α_4 je negativan. Različita kompozicija sektorskih struktura zemalja implicira različitu osjetljivost kod pojave industrijski specifičnih šokova. Dodatno, zemlje različito reagiraju kod pojave zajedničkih šokova (npr. promjene kamatnih stopa ili promjena cijene nafte) što negativno utječe na usklađivanje njihovih poslovnih ciklusa.

Ricardov teorem predviđa da trgovinska integracija potiče specijalizaciju zemalja u skladu s komparativnim prednostima koje proizlaze iz razlika u tehnologiji. Slično tome, Heckscher-Ohlinov teorem predviđa da trgovinska integracija potiče zemlje na specijalizaciju (u proizvodnji dobara) u skladu s komparativnim prednostima koje proizlaze iz raspoloživosti faktora proizvodnje. Specijalizacija zemalja u skladu s navedenim teoremima uzrokuje divergenciju njihovih sektorskih struktura. S druge strane, ako je dominantni tip trgovine intra-industrijska trgovina (Linderova hipoteza) trgovinska integracija povezana je sa sličnijom kompozicijom sektorskih struktura zemalja. U skladu s navedenim, očekivani predznak parametra β_1 nije jednoznačan.

Kalemli-Ozcan i ostali (2003) ističu da financijska integracija putem podjele rizika potiče specijalizaciju zbog boljeg prekograničnog osiguranja prihoda. Dodatno, Obstfeld (1994) ističe da financijska integracija pomiče investicije prema rizičnijim projektima što omogućava zemljama da se specijaliziraju u skladu s komparativnim prednostima. Na taj način dolazi do divergencije sektorskih struktura zemalja. S druge strane, financijska integracija može potaknuti specijalizaciju u istim proizvodnim djelatnostima, npr. u situaciji kad se izravne strane investicije koncentriraju u sektorima u kojima zemlja davatelj izravnih stranih investicija ima komparativne prednosti, replicirajući na taj način svoju proizvodnu strukturu drugoj zemlji (Garcia-Herrero i Ruiz, 2008).

U tom slučaju dolazi do konvergencije proizvodnih struktura zemalja. Dakle, očekivani predznak parametra β_2 nije jednoznačan.

Veće zemlje u pravilu imaju diversificiraniju sektorsku strukturu. U skladu s time imat će sličniju sektorsku kompoziciju Dakle, očekuje se pozitivan predznak parametra β_3.

Imbs i Wacziarg (2003) ističu da se specijalizacija (sektorska koncentracija) nije linearna već ima oblik slova U, a mijenja se ovisno o stupnju razvijenosti zemalja. Na nižem stupnju razvoja (dohotka po glavi stanovnika) zemlje smanjuju stupanj specijalizacije da izbjegnu negativne učinke sektorski specifičnih šokova, dok se na višem stupnju razvoja zemlje ponovno specijaliziraju da bi u potpunosti iskoristile komparativne prednosti. U skladu s navedenim, očekivani predznak parametra β_4 nije jednoznačan.

Očekivani predznak parametra γ_1 nije jednoznačan. Naime, financijska integracija omogućava lakši i jeftiniji pristup trgovinskim kreditima i na taj način potiče trgovinu (trgovinsku integraciju). Dodatno, vertikalne izravne strane investicije, kod kojih su različite faze proizvodnje locirane u različitim zemljama (zbog smanjenja proizvodnih troškova), djeluju kao komplement trgovini. S druge strane, ako su izravne strane investicije dominantno horizontalnog tipa (horizontalne FDI), onda financijska integracija djeluje kao supstitut trgovini što implicira negativan odnos između financijske i trgovinske integracije.

Očekivani predznak parametra γ_2 nije jednoznačan. Različita kompozicija sektorskih struktura zemalja implicira veći stupanj trgovine između njih radi iskorištavanja komparativnih prednosti. S druge strane, Linderova hipoteza implicira da zemlje sa sličnijim sektorskim strukturama više trguju jedna s drugom.

5.2. Varijable i indikatori

Iz empirijskog modela prikazanog u prethodnom potpoglavlju vidljivo je da usklađenost poslovnih ciklusa predstavlja glavnu zavisnu varijablu. Za nezavisne varijable u modelu koriste se financijska integracija, trgovinska integracija, sličnost sektorskih struktura i konvergencija

fiskalnih politika. S obzirom na potrebu analize neizravnih kanala utjecaja financijske integracije na usklađivanje poslovnih ciklusa putem kanala specijalizacije i trgovinske integracije, u jednadžbi (2) sličnost sektorskih struktura predstavlja zavisnu varijablu, a u jednadžbi (3) trgovinska integracija predstavlja zavisnu varijablu. U nastavku su prikazani indikatori i način mjerenja navedenih varijabli te su navedeni korišteni izvori podataka.

5.2.1. Usklađenost poslovnih ciklusa

Poslovne cikluse nije moguće izravno izmjeriti, već ih je potrebno procijeniti. U dosadašnjim istraživanjima koriste se različite metode procjene poslovnih ciklusa i različite mjere usklađenosti poslovnih ciklusa. Darvas, Rose i Szapary (2007) za indikator poslovnih ciklusa koriste tri mjere ekonomske aktivnosti - realni BDP, stopu nezaposlenosti i industrijsku proizvodnju. Poslovne cikluse procjenjuju primjenom Hodrick-Prescottovog (HP) filtra, a usklađenost poslovnih ciklusa mjere Pearsonovim koeficijentom korelacije. Na isti način procjenjuju poslovne cikluse i mjere stupanj njihove usklađenosti: Alimi (2015), Antonakakis i Tondl (2014) te Fonseca, Patureau i Sopraseuth (2010).

Inklaar, Jong-A-Pin i De Haan (2008) za indikator poslovnog ciklusa koriste dva pokazatelja realne ekonomske aktivnosti: realni kvartalni BDP i indeks industrijske proizvodnje. Za indeks industrijske proizvodnje ističu da je zanimljiv jer je dostupan za dulji vremenski period na mjesečnoj frekvenciji (za razliku od kvartalnog BDP-a). Poslovne cikluse procjenjuju primjenom Baxter-Kingovog filtra. Isti filtar koriste Bower i Gullemineau (2006) i Akin (2012), pri čemu Akin (2012) normalnost distribucije postiže korištenjem Fisherove z-transformacije. Kao i ostali, usklađenost poslovnih ciklusa mjere Pearsonovim koeficijentom korelacije.

Za razliku od njih, Artis, Fidrmuc i Scharler (2008) poslovne cikluse procjenjuju četvrtim diferencijama kvartalnog realnog BDP-a desezoniranog X12 ARIMA procedurom. Usklađenost poslovnih ciklusa mjere istovremenom (engl. contemporaneous) korelacijom za koju ističu da ima izravne implikacije za potencijalne troškove monetarnog integriranja. Dodatno, da bi izbjegli ograničenje zavisne varijable u intervalu [-1,1] koriste Fisherovu transformaciju koeficijenta korelacije.

Lukmanova i Tondl (2017) usklađenost poslovnih ciklusa mjere metodom dinamičke uvjetne korelacije koja pripada klasi multivarijatnih GARCH modela.

Većina navedenih istraživanja poslovne cikluse procjenjuje izoliranjem cikličke komponente uz pomoć HP filtra koji pripada skupini visoko pojasnih filtara. HP filtar eliminira fluktuacije s frekvencijom većom od 32 kvartala i stavlja ih u trend. Razdvajanje vremenske serije na trend i cikličku komponentu svodi se na rješavanje problema minimizacije:

$$\min_{\tau}\{\sum_{t=1}^{T}(y_t-\tau_t)^2+\lambda\sum_{t=2}^{T-1}[(\tau_{t+1}-\tau_t)-(\tau_t-\tau_{t-1})]^2\} \quad ,$$

gdje y predstavlja vremensku seriju, τ predstavlja trend, a λ multiplikator. Rješenje problema minimizacije sastoji se od odabira takve trendovske serije $\{\tau\}_{t=1}^{T}$ koja minimizira gornju sumu kvadrata. Multiplikator λ predstavlja trošak uključivanja fluktuacija u trend, pri čemu veća vrijednost parametra jače izglađuje trendovsku komponentu. Preporučene vrijednosti parametra izglađivanja λ su: λ=14400 za vremenske serije na mjesečnoj frekvenciji; λ=1600 za vremenske serije na kvartalnoj frekvenciji; i λ=100 Za vremenske serije na godišnjoj frekvenciji.

Iako je zbog jednostavnosti primjene često korišten u sličnim istraživanjima, njegova upotreba uključuje nekoliko problema. Akin (2012) ističe da se kritike korištenja HP filtra najčešće odnose na arbitraran izbor parametra izglađivanja λ koji ovisi o preferencijama korisnika. Također, u slučaju primjene na serije stacionirane u diferencijama umjetno pojačava frekvencije poslovnog ciklusa i inducira podmetnuti (engl. spurious) ciklus. Dalje, u slučaju pojave trajnih šokova HP filtar generira pomake u trendu koje stvarno ne postoje čime izglađuje učinak iznenadnih strukturnih prekida u prethodnim i budućim razdobljima. Jovičić (2017) ističe da je HP dvostrani simetrični filtar i da se zbog toga procjene pri kraju uzorka mogu osjetno promijeniti s dolaskom novih opažanja (engl. end-of-sample problem). Osim toga, HP filtar je u potpunosti statistički pristup procjeni potencijalnog BDP-a koji nije izravno povezan s ekonomskom teorijom.

Zbog navedenih ograničenja, u ovom istraživanju poslovni ciklusi procijenjeni su korištenjem jaza outputa koji su izračunati prema metodi proizvodne funkcije. Za razliku od statističkih pretpostavki koje se koriste kod izračuna trenda iz vremenskih serija korištenjem univarijatnih filtara, metoda proizvodne funkcije koristi pretpostavke koje se temelje na ekonomskoj teoriji.

Navedena metoda implicitno definira potencijalni output kao razinu proizvodnje koja se može ostvariti tijekom dužeg razdoblja bez prekomjernog iskorištavanja postojećih proizvodnih kapaciteta. Pretpostavlja Cobb-Douglasov oblik proizvodne funkcije:

$$Y_t = TFP_t * L_t^{\beta} * K_t^{(1-\beta)} \quad ,$$

gdje Y_t označava bruto domaći proizvod, TFP_t ukupnu faktorsku produktivnost, L_t količinu upotrijebljenog rada, K_t količinu kapitala, a β udio faktora rada u bruto domaćem proizvodu. Specifikacija proizvodne funkcije temelji se na pretpostavci konstantnih prinosa na opseg (β=0,65). Izračun jaza BDP-a zahtijeva procjenu potencijalnog BDP-a koja se sastoji od procjene trenda zaposlenosti i trenda ukupne faktorske produktivnosti[27]. Trend ukupne faktorske produktivnosti procijenjen je iz Solowljevog reziduala korištenjem bivarijatnog Kalmanovog filtra (Havik i ostali, 2014). Procjena trenda zaposlenosti definira se na način:

$$L = POP * PART * H * (1 - NAWRU) \quad ,$$

gdje *POP* označava ukupnu radno sposobnu populaciju, *PART* trendovsku stopu participacije, *H* trend prosječnih sati rada po radniku, a *NAWRU* strukturnu nezaposlenost.

Konačno, jaz outputa (Y_{gap}) računa se prema formuli:

$$Y_{gap} = \left(\frac{Y_{act}}{Y_{pot}} - 1\right) \quad ,$$

Gdje Y_{pot} predstavlja potencijalni output, a Y_{act} realizirani output.

Velika prednost metode proizvodne funkcije je u tome što se pomoću nje rast potencijalnog BDP-a može rastaviti na doprinose rada, kapitala i ukupne faktorske produktivnosti. Zbog toga je u svojim analizama primjenjuju HNB, Europska središnja banka i Europska komisija (Jovičić, 2017).

[27] Jovičić (2017) ističe da se zbog nedostatka pouzdanih pokazatelja o iskorištenosti proizvodnih kapaciteta u procjeni potencijalnog BDP-a uzima originalna vremenska serija kapitala, tj. pretpostavlja se da je cjelokupni kapital iskorišten cijelo vrijeme.

U većini dosadašnjih istraživanja usklađenost poslovnih ciklusa mjeri se Pearsonovim koeficijentom korelacije, a iako je on konstruiran iz vremenske serije pripada skupini statičkih pokazatelja jer nema vremensku dimenziju. Kamanduliene i Lydeka (2011) ističu da Pearsonov koeficijent pokazuje relativnu usklađenost, ali nije sposoban prikazati evoluciju usklađivanja poslovnih ciklusa, tj. dinamiku promjene. Statički pokazatelji uglađuju promjenu u vremenu, a što je duže vremensko razdoblje veći je stupanj uglađivanja. Antonakakis i Tondl (2014) obuhvaćaju vremensku komponentu korištenjem pomičnog prosjeka (engl. rolling windows), ali takav pristup rezultira varijablama koje su autokorelirane te je stoga takvim varijablama teško upravljati u ekonometrijskoj analizi.

Izračun Pearsonovog koeficijenta korelacije zahtijeva dulju vremensku seriju[28] što implicira uglađivanje varijabli u modelu, tj. gubitak njihove vremenske dinamike. Na taj način uzorak djelomično ili u potpunosti gubi strukturu panela. Za uklanjanje navedenog problema u ovom istraživanju korišten je koeficijent dinamičke korelacije po uzoru na Cerqueiru i Martinsa (2009).

Cerquiera-Martins korelacijski indeks računa se prema sljedećoj formuli:

$$\rho_{ijt} = 1 - \frac{1}{2}\left(\frac{(d_{jt}-\overline{d}_j)}{\sqrt{\frac{1}{T}\sum_{t=1}^{T}(d_{jt}-\overline{d}_j)^2}} - \frac{(d_{it}-\overline{d}_i)}{\sqrt{\frac{1}{T}\sum_{t=1}^{T}(d_{it}-\overline{d}_i)^2}}\right)^2 ,$$

gdje d_{it} stopu rasta BDP-a zemlje i u razdoblju t, a $\overline{d}_i$ prosječnu stopu rasta BDP-a zemlje i u cjelokupnom promatranom razdoblju. Viša vrijednost indeksa označava veći stupanj usklađenosti poslovnog ciklusa Hrvatske i promatrane zemlje eurozone.

Korištenje Cerquiera-Martins korelacijskog indeksa ima prednosti u odnosu na statičke indikatore jer: (i) nema potrebe postavljanja vremenskog okvira, (ii) nema gubitka opažanja i (iii) ne pokazuje tzv. „značajke duhova“ (Cerqueira i Martins, 2009). Osim uvođenja dinamičke komponente u analizu, korištenje navedenog indikatora omogućava maksimalno iskorištenje uzorka (broja opažanja) što je poželjno zbog specifičnosti analize koja uključuje relativno manji broj opažanja u odnosu na ostala istraživanja.

[28] U slučaju korištenja kvartalnog BDP-a najčeće se uzima 20 opažanja, tj. vremensko razdoblje od 5 godina.

Za razliku od istraživanja Cerquiere i Martinsa (2009), koji za indikator poslovnog ciklusa koriste stopu rasta realnog BDP-a, u ovom istraživanju koristi se jaz outputa (engl. output gap) zbog svih prethodno navedenih prednosti. Podaci o jazu outputa Hrvatske i zemalja eurozone preuzeti su iz AMECO-ve baze podataka (annual macro-economic database of the European Commission's Directorate General for Economic and Financial Affairs).

Na grafikonu 1. prikazana je usklađenost poslovnog ciklusa Hrvatske s poslovnim ciklusima zemalja eurozone u razdoblju od 2001. do 2016. godine mjerena Cerquiera-Martinsovim korelacijskim indeksom. Dodatno, u prilogu 1. prikazano je kretanje poslovnog ciklusa Hrvatske i poslovnih ciklusa zemalja eurozone u razdoblju od 2001. do 2016. godine iz kojih se može uočiti njihova amplitudna usklađenost. Usklađenost poslovnog ciklusa Hrvatske sa zemljama eurozone značajno oscilira po pitanju prostorne (prema različitim zemljama eurozone) i vremenske (u različitim godinama) dimenzije što otežava donošenje jednoznačnog zaključka o prikladnosti zajedničke monetarne politike, tj. troškovima prihvaćanja eura za Hrvatsku.

Naime, Hrvatska je u razdoblju od 2001. do 2008. godine imala relativno visoki stupanj usklađenosti poslovnog ciklusa sa zemljama eurozone, što implicira da u navedenom razdoblju nije bilo snažnog djelovanja idiosinkratskih šokova. Međutim, u istom razdoblju stupanj usklađenosti poslovnog ciklusa Hrvatske s Austrijom, Belgijom, Njemačkom i Slovačkom nije na razini usklađenosti s poslovnim ciklusima ostalih zemalja eurozone.

Do naglog pada usklađenosti poslovnog ciklusa Hrvatske s poslovnim ciklusima zemalja eurozone dolazi 2009. godine s pojavom globalne financijske krize. U navedenoj godini opada usklađenost poslovnog ciklusa Hrvatske s poslovnim ciklusima Austrije, Belgije, Estonije, Finske, Francuske, Njemačke, Grčke, Irske, Italije, Latvije, Letonije, Luxemburga te Španjolske. Posebno se ističe niži stupanj usklađenosti poslovnog ciklusa Hrvatske s poslovnim ciklusom Njemačke (čiji poslovni ciklus ima veliki udio kod definiranja zajedničke monetarne politike eurozone) - u navedenoj godini varijabla usklađenost poslovnih ciklusa poprima negativnu vrijednost. S dijelom (većinom rubnih) zemalja eurozone (Malta, Nizozemska, Portugal, Slovačka) Hrvatska je i u godinama krize zadržala relativno visoki stupanj usklađenosti (ne samo po pitanju faze poslovnog ciklusa, već i po pitanju amplitude poslovnog ciklusa) što je posljedica snažnije kontrakcije njihovih poslovnih ciklusa i duljeg oporavka u odnosu na zemlje jezgre eurozone. Iz navedenog je

očigledno da su zemlje eurozone heterogene što stvara probleme kod vođenja zajedničke monetarne politike.

S obzirom na važnost zemalja jezgre kod definiranja zajedničke monetarne politike eurozone, jasno je da bi Hrvatska u kriznim godinama imala dodatne probleme zbog neodgovarajeće monetarne politike u slučaju da je prihvatila euro. Navedeno indicira da će Hrvatska prihvatiti euro u "mirnim" vremenima jer su tada manje izraženi problemi neusklađenih poslovnih ciklusa, tj. neprikladne zajedničke monetarne politike.

Grafikon 1. Usklađenost poslovnih ciklusa Hrvatske sa zemljama eurozone (BCS)

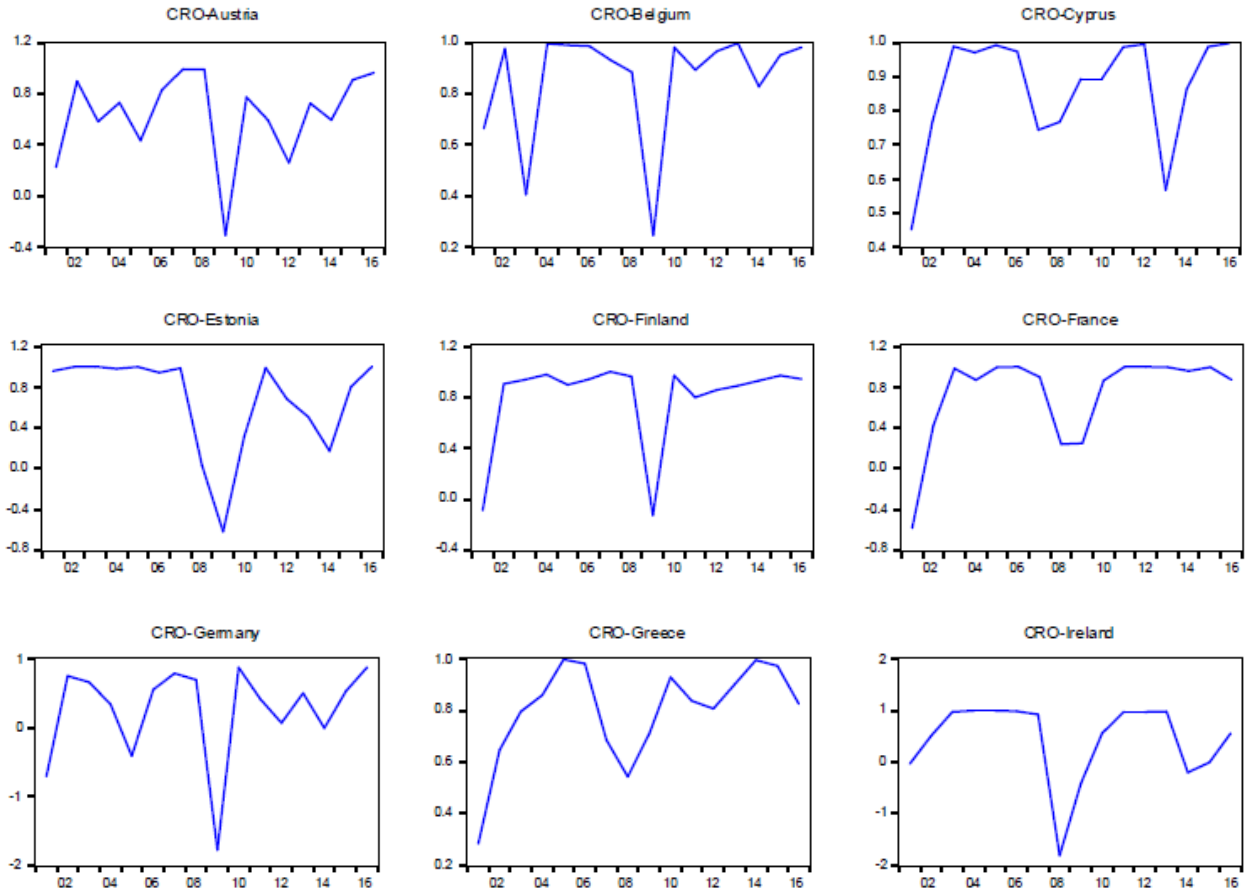

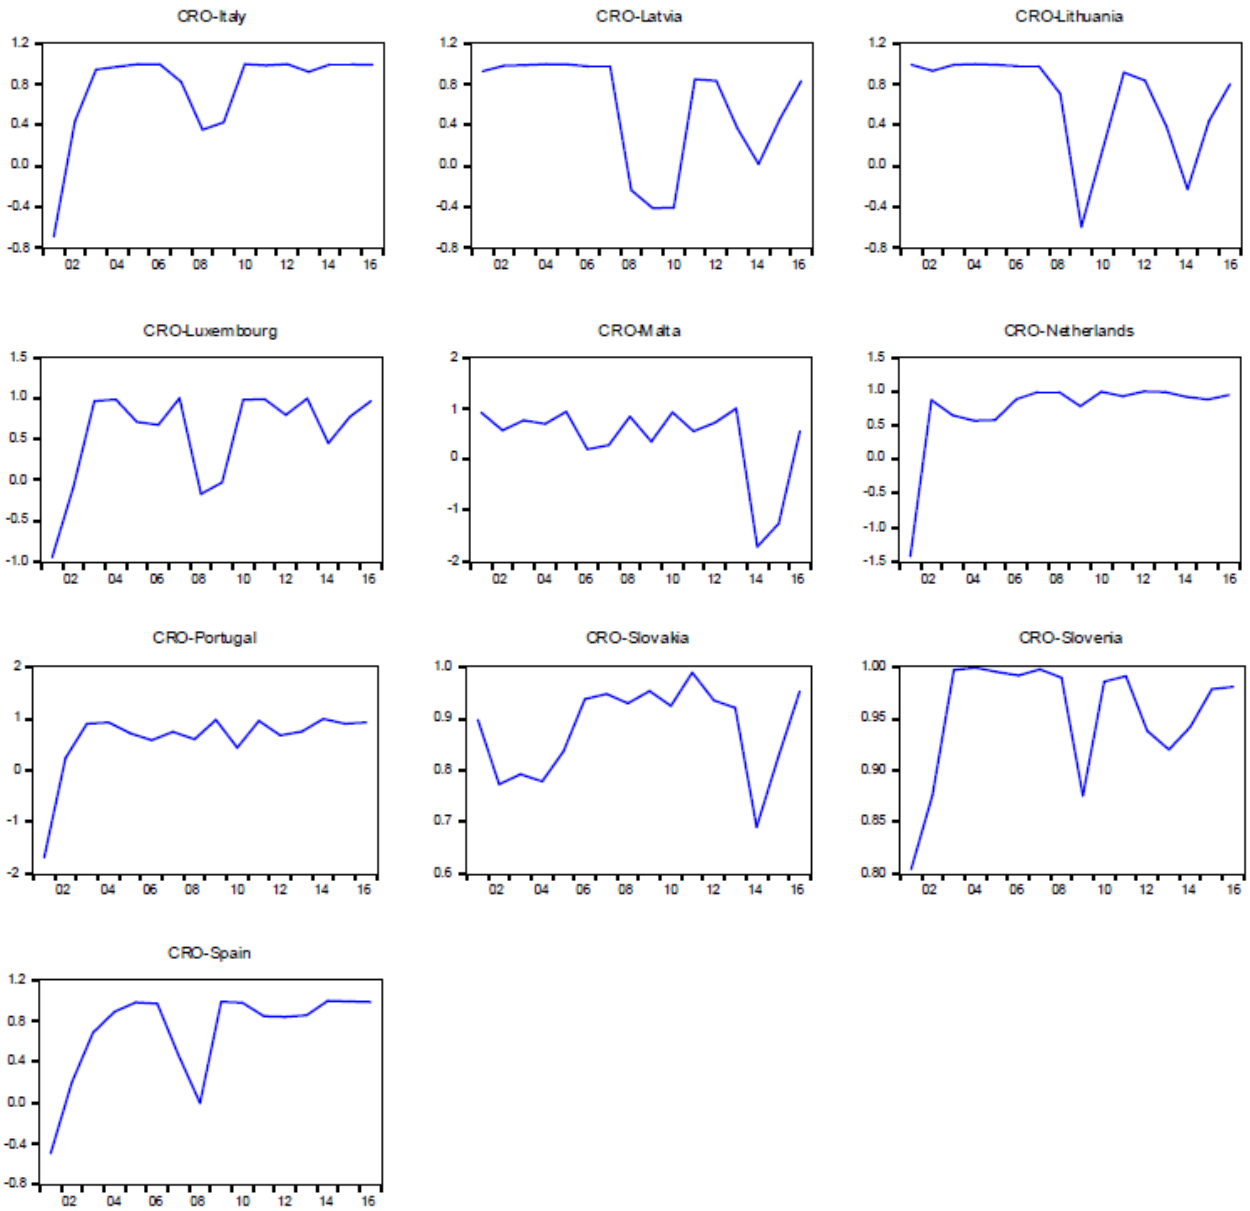

Izvor: Izrada autora (EViews 9)

Do usklađivanja poslovnog ciklusa Hrvatske s poslovnim ciklusima zemalja eurozone kratkoročno dolazi 2010. Godine. S pojavom europske dužničke krize usklađenost poslovnog ciklusa Hrvatske s poslovnim ciklusima zemalja eurozone varira ovisno o promatranoj zemlji – smanjuje se usklađenost poslovnih ciklusa Hrvatske i Njemačke te Austrije (zemljama koje su slabije osjetile krizu), a raste prema zemljama koje su jače pogođene krizom (Grčka, Irska, Italija,

Portugal, Španjolska). Iako su sve zemlje eurozone pogođene krizom, očigledno je da je europska dužnička kriza (kao i globalna financijska kriza) uzrokovala stvaranje snažnih idiosinkratskih šokova i otežala provođenje jedinstvene monetarne politike na razini eurozone. U takvoj situaciji (neusklađenih poslovnih ciklusa) gubitak vlastite monetarne politike stvorio bi dodatne troškove za Hrvatsku. Dodatno, iz grafikona je vidljivo da je 2014. također došlo do pada usklađenosti poslovnog ciklusa Hrvatske s dijelom zemalja eurozone, nakon čega u 2015. i 2016. ponovno dolazi do porasta usklađenosti.

5.2.2. Financijska integracija

Financijska integracija (FI1) mjeri se udjelom bilateralnih izravnih stranih investicija u bruto domaćim proizvodima zemalja:

$$FI1_{ijt} = \frac{fi_{ijt} + fo_{ijt}}{Y_{it} + Y_{jt}} \quad ,$$

gdje fi_{ijt} predstavlja kumulativni priljev izravnih stranih investicija iz zemlje *i* u zemlju *j* u razdoblju *t*, fo_{ijt} kumulativni odljev izravnih stranih investicija iz zemlje *i* u zemlju *j* u razdoblju *t*, a Y_{it} nominalni BDP zemlje *i* u razdoblju *t*.

Viša vrijednost indikatora FI1 označava veći stupanj financijske integracije između Hrvatske i pojedine zemlje eurozone. Podaci o kumulativnom priljevu i odljevu izravnih stranih investicija preuzeti su iz WIIW-ove (The Wiena Institute for International Economic Studies) baze podataka.

Na grafikonu 2. prikazana je financijska integracija (FI1) Hrvatske sa zemljama eurozone u razdoblju od 2001. do 2016. godine mjerena bilateralnim kumulativnim priljevom i odljevom izravnih stranih investicija.

Grafikon 2. Financijska integracija (FI1) Hrvatske sa zemljama eurozone

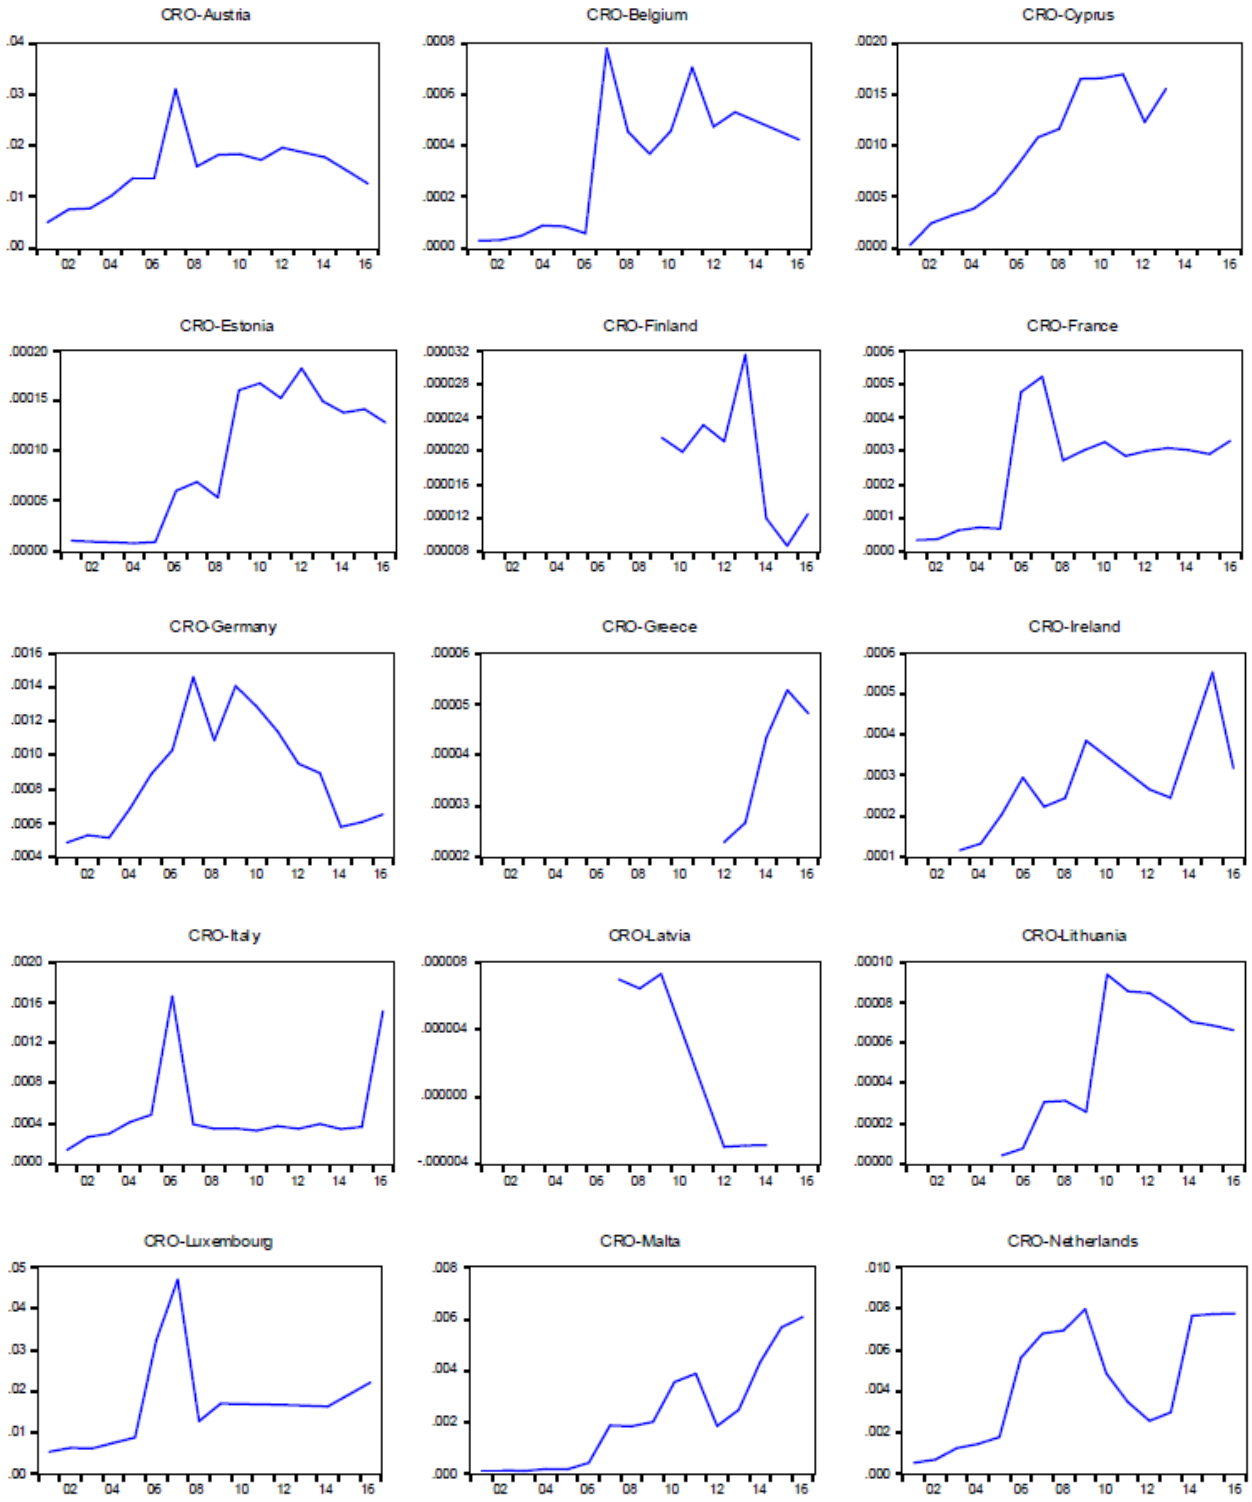

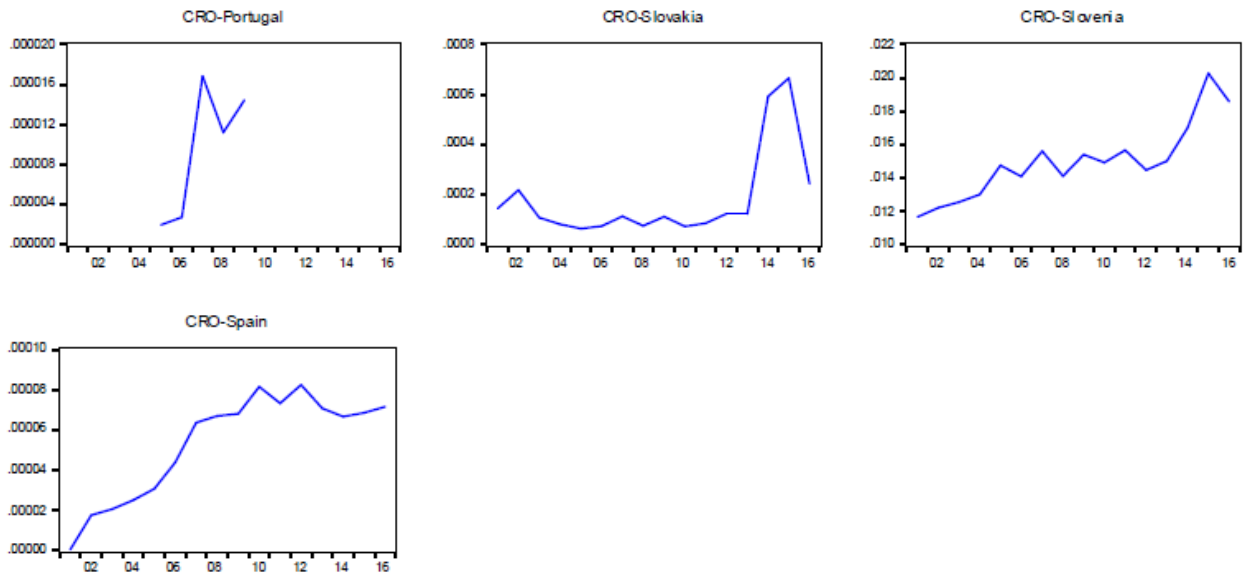

Izvor: Izrada autora (EViews 9)

Kumulativni priljev izravnih stranih investicija iz zemalja eurozone u Hrvatsku kontinuirano snažno raste od 2001. (3.243,1 mil. €) do 2007. godine (25.144,3 mil. €). U 2008. godini dolazi do snažnog pada kumulativnog priljeva FDI-a (15.564,18 mil. €), a do potpunog oporavka i povratka na razinu priljeva iz 2007. još nije došlo (kumulativni priljev FDI-a u 2016. godini iznosio je 18.973,7 mil. €).

Najveći kumulativni priljev izravnih stranih investicija iz zemalja eurozone Hrvatska je u 2016. godini ostvarila iz Austrije (5.038,9 mil. €), Nizozemske (4.672,4 mil. €), Italije (2.626,5 mil. €), Luksemburga (2.245,1 mil. €), Njemačke (2.049,42 mil. €), Francuske (756,55 mil. €) i Slovenije (677,7 mil. €). S druge strane, kumulativni priljev izravnih stranih investicija iz Estonije, Finske, Grčke, Latvije, Litve, Portugala, Slovačke i Španjolske u 2016. čini tek 0,73% ukupnog priljeva izravnih stranih investicija iz zemalja eurozone.

Promatrajući odnos priljeva i odljeva kapitala očigledno je da je Hrvatska u promatranom razdoblju bila neto uvoznica kapitala, a globalna financijska kriza i europska dužnička kriza značajno su utjecale na nagli zastoj (engl. sudden stop) kretanja kapitala.

Osim količinskim indikatorom (FI1), financijska integracija u ovom istraživanju mjeri se i cjenovnim indikatorom (FI3) – apsolutnom razlikom povrata na desetogodišnje obveznice:

$$FI3_{ijt} = |r_{it} - r_{jt}| \quad ,$$

gdje r_{it} predstavlja realnu stopu povrata na desetogodišnje obveznice zemlje i u razdoblju t, a r_{jt} realnu stopu povrata na desetogodišnje obveznice zemlje j u razdoblju t. Što je manja razlika između realnih stopa povrata na desetogodišnje obveznice veći je stupanj financijske integracije između promatranih zemalja. Dakle, zbog načina mjerenja, viša vrijednost varijable FI3 označava manji stupanj financijske integracije između zemalja. Podaci o realnim stopama povrata na desetogodišnje obveznice zemalja preuzeti su iz Eurostatove baze podataka.

Podaci o realnoj stopi povrata na hrvatske desetogodišnje obveznice za razdoblje od 2001. do 2006. godine ne postoje pa su su izračunati po uzoru na Aljinović i ostale (2010).

Na grafikonu 3. prikazan je stupanj financijske integracije između Hrvatske i zemalja eurozone u razdoblju od 2001. do 2016. godine mjeren apsolutnom razlikom realnih stopa povrata na desetogodišnje obveznice.

Grafikon 3. Financijska integracija (FI3) Hrvatske sa zemljama eurozone (2001.-2016.)

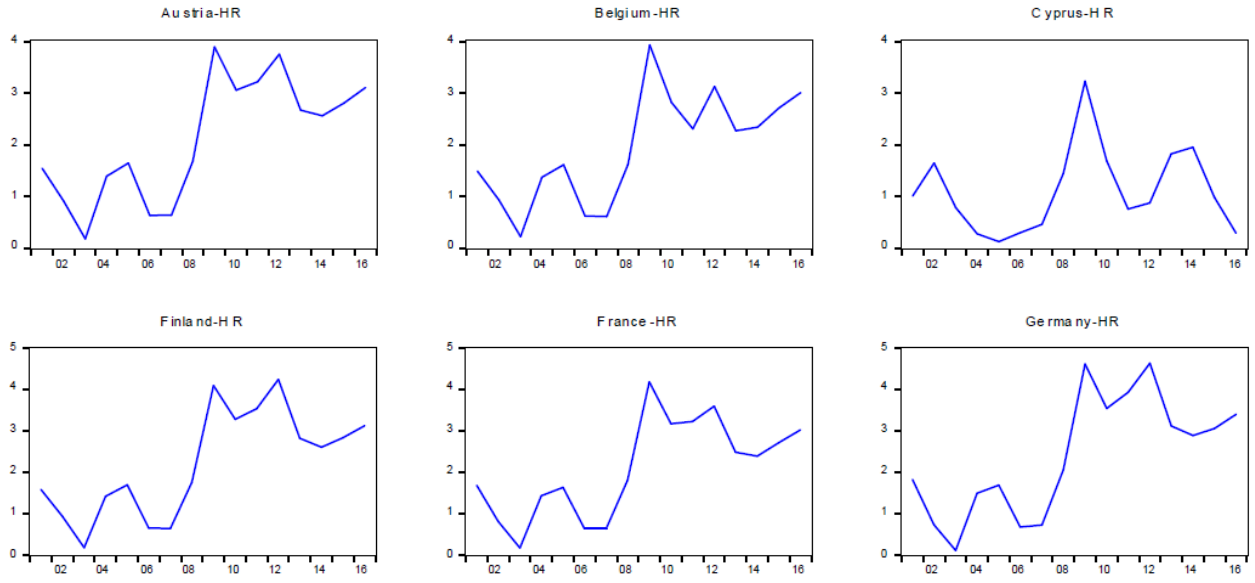

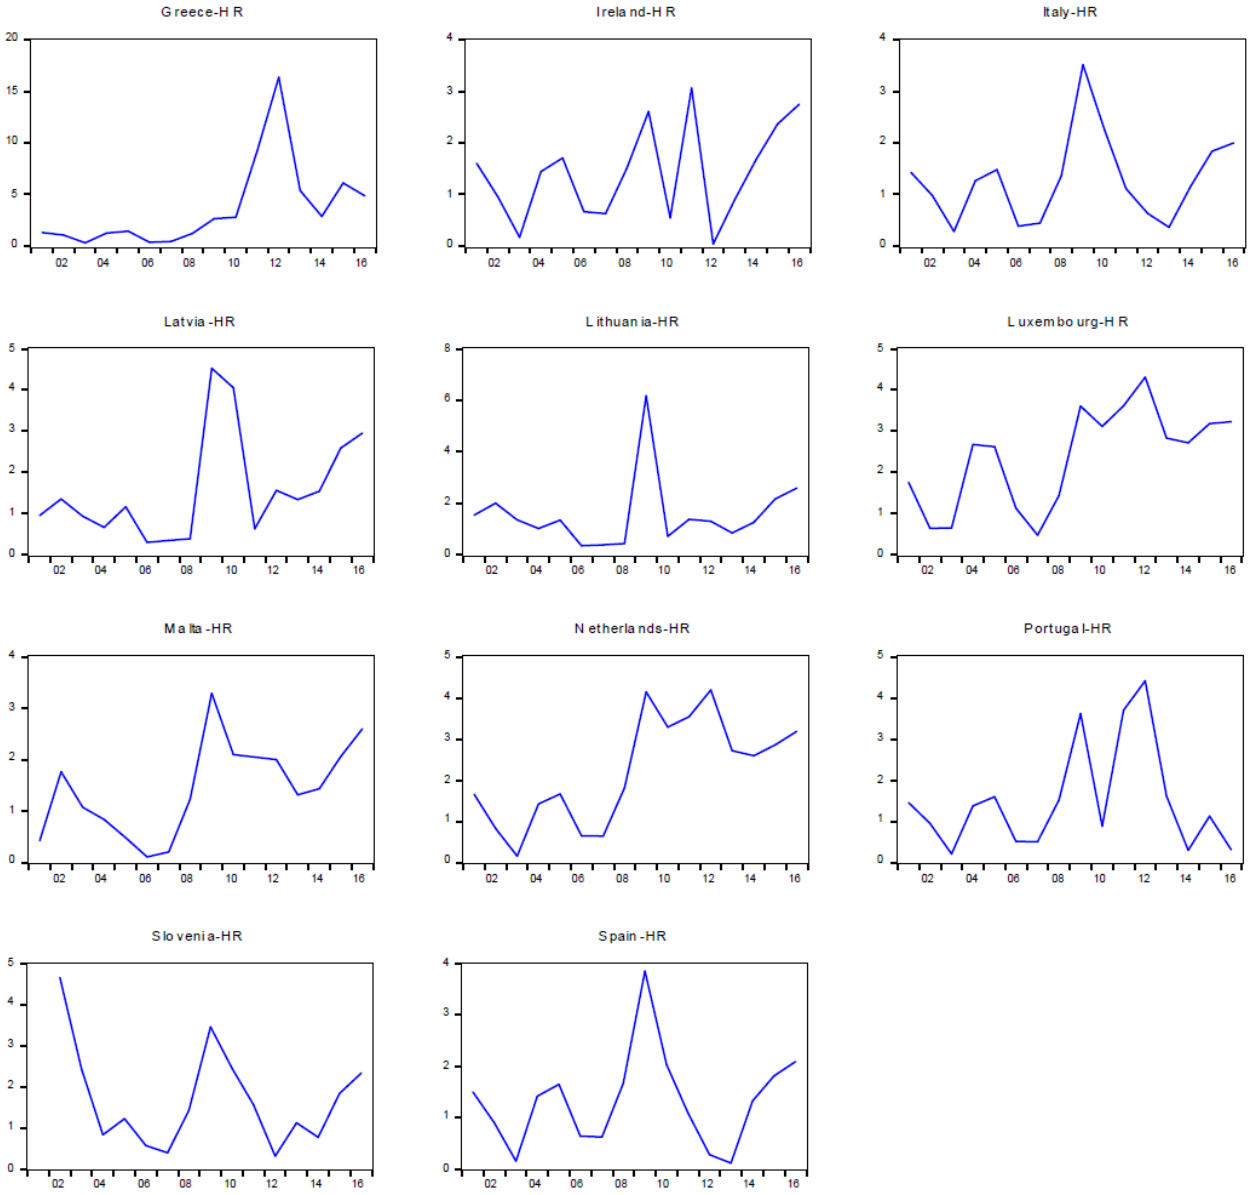

Izvor: Izrada autora (EViews 9)

Iz grafikona je vidljivo da u razdoblju od 2001. do 2007. godine postoji visok stupanj financijske integracije (FI3) između Hrvatske i zemalja eurozone. Naime, u navedenom razdoblju apsolutna razlika realnih stopa povrata na desetogodišnje obveznice Hrvatske i zemalja eurozone kreće se u rasponu od 1 do 2 postotna poena, a neposredno prije globalne krize spušta se ispod jednog postotnog poena.

S pojavom globalne financijske krize i europske dužničke krize dolazi do snažne divergencije realnih stopa povrata na desetogodišnje obveznice zbog pojave averzije prema riziku i reevaluacije kreditnog rizika.

5.2.3. Trgovinska integracija

Trgovinska integracija (TI1) mjeri se udjelom bilateralnog robnog uvoza i robnog izvoza u BDP-ovima zemalja po uzoru na Frankela i Rosea (1998):

$$TI1_{ijt} = \frac{x_{ijt}+m_{ijt}}{Y_{it}+Y_{jt}} \quad ,$$

gdje x_{ijt} predstavlja izvoz zemlje *i* u zemlju *j* u razdoblju *t*, m_{ijt} uvoz zemlje *i* iz zemlje *j* u razdoblju *t*, a Y_{it} nominalni BDP zemlje *i* u razdoblju *t*. Viša vrijednost pokazatelja označava veći stupanj trgovinske integracije između Hrvatske i promatrane zemlje eurozone. Podaci o robnom uvozu i izvozu zemalja preuzeti su iz repozitorija službene međunarodne trgovinske statistike - UN Comtrade-ove baze podataka.

Iako bi sveobuhvatni trgovinski tokovi trebali uključivati i usluge, podaci o bilateralnoj trgovini uslugama između Hrvatske i zemalja eurozone nisu dostupni, te u skladu s time usluge nisu uključene kod izračuna varijable trgovinske integracije.

Alternativno, trgovinska integracija (TI2) mjeri se udjelom robnog uvoza i robnog izvoza između zemalja u odnosu na njihov ukupni robni uvoz i robni izvoz, također po uzoru na Frankela i Rosea (1998):

$$TI2_{ijt} = \frac{x_{ijt}+x_{ijt}}{x_{it}+m_{it}+x_{jt}+m_{jt}} \quad ,$$

gdje x_{it} predstavlja ukupni nominalni robni izvoz zemlje *i* u razdoblju *t*, a m_{it} ukupni nominalni robni uvoz zemlje *i* u razdoblju *t*.

Na grafikonu 4. prikazan je stupanj trgovinske integracije Hrvatske sa zemljama eurozone mjeren udjelom bilateralnog robnog uvoza i izvoza između Hrvatske i zemalja eurozone u sumi njihovih BDP-ova u razdoblju od 2001. do 2016. godine.

Najveći dio (88,6%) robnog uvoza Hrvatske iz zemalja eurozone u 2016. godini (12.014,2 mil. €) ostvaren je iz šest zemalja: Njemačke (3178,1 mil. €), Italije (2489 mil. €), Slovenije (2.154,4 mil. €), Austrije (1.571,3 mil. €), Nizozemske (773,6 mil. €) i Francuske (478,4 mil. €). S druge strane, robni uvoz iz Cipra, Estonije, Finske, Latvije, Letonije, Luksemburga, Malte i Portugala čini tek jedan posto ukupnog robnog uvoza Hrvatske iz zemalja eurozone u 2016. godini. Robni uvoz Hrvatske iz zemalja eurozone kontinuirano je rastao od 2001. (6.229,6 mil. €) do 2008. (10.862,5 mil. €) što predstavlja rast od 74,4%. U 2009. godini dolazi do snažnog pada robnog uvoza iz zemalja Eurozone, a na razinu iz 2008. godine vraća se tek u 2015. godini (11.410,2 mil. €).

Robni izvoz Hrvatske u zemlje eurozone u 2016. godini iznosio je 6.848,4 mil. €, pri čemu se najveći dio (77,2%) odnosi na izvoz u Italiju (1.684,5 mil. €), Sloveniju (1.539,4 mil. €), Njemačku (1.453,2 mil. €), Francusku (289,2 mil. €) i Nizozemsku (322,8 mil. €). Slično kao i kod uvoza, robni izvoz u sedam zemalja (Cipar, Estoniju, Finsku, Litvu, Latviju, Luksemburg i Maltu) čini tek 1,86% izvoza prema zemljama eurozone.. Robni izvoz Hrvatske u zemlje eurozone rastao je od 2001. (3.274,7 mil. €) do 2008. (4.993,5 mil. €) nakon čega slijedi snažan pad u 2009. godini (3.957,2 mil. €). Međutim, za razliku od uvoza, izvoz se već u 2011. (4.982,8 mil. €) vraća na razinu 2008. godine.

Grafikon 4. Trgovinska integracija Hrvatske sa zemljama Eurozone (TI1)

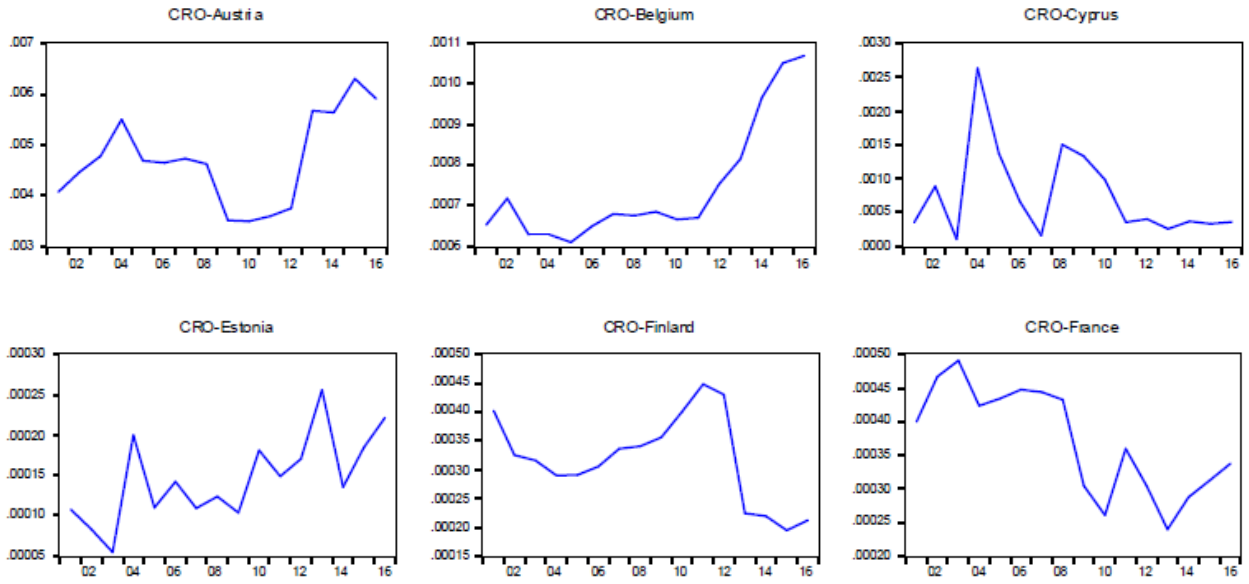

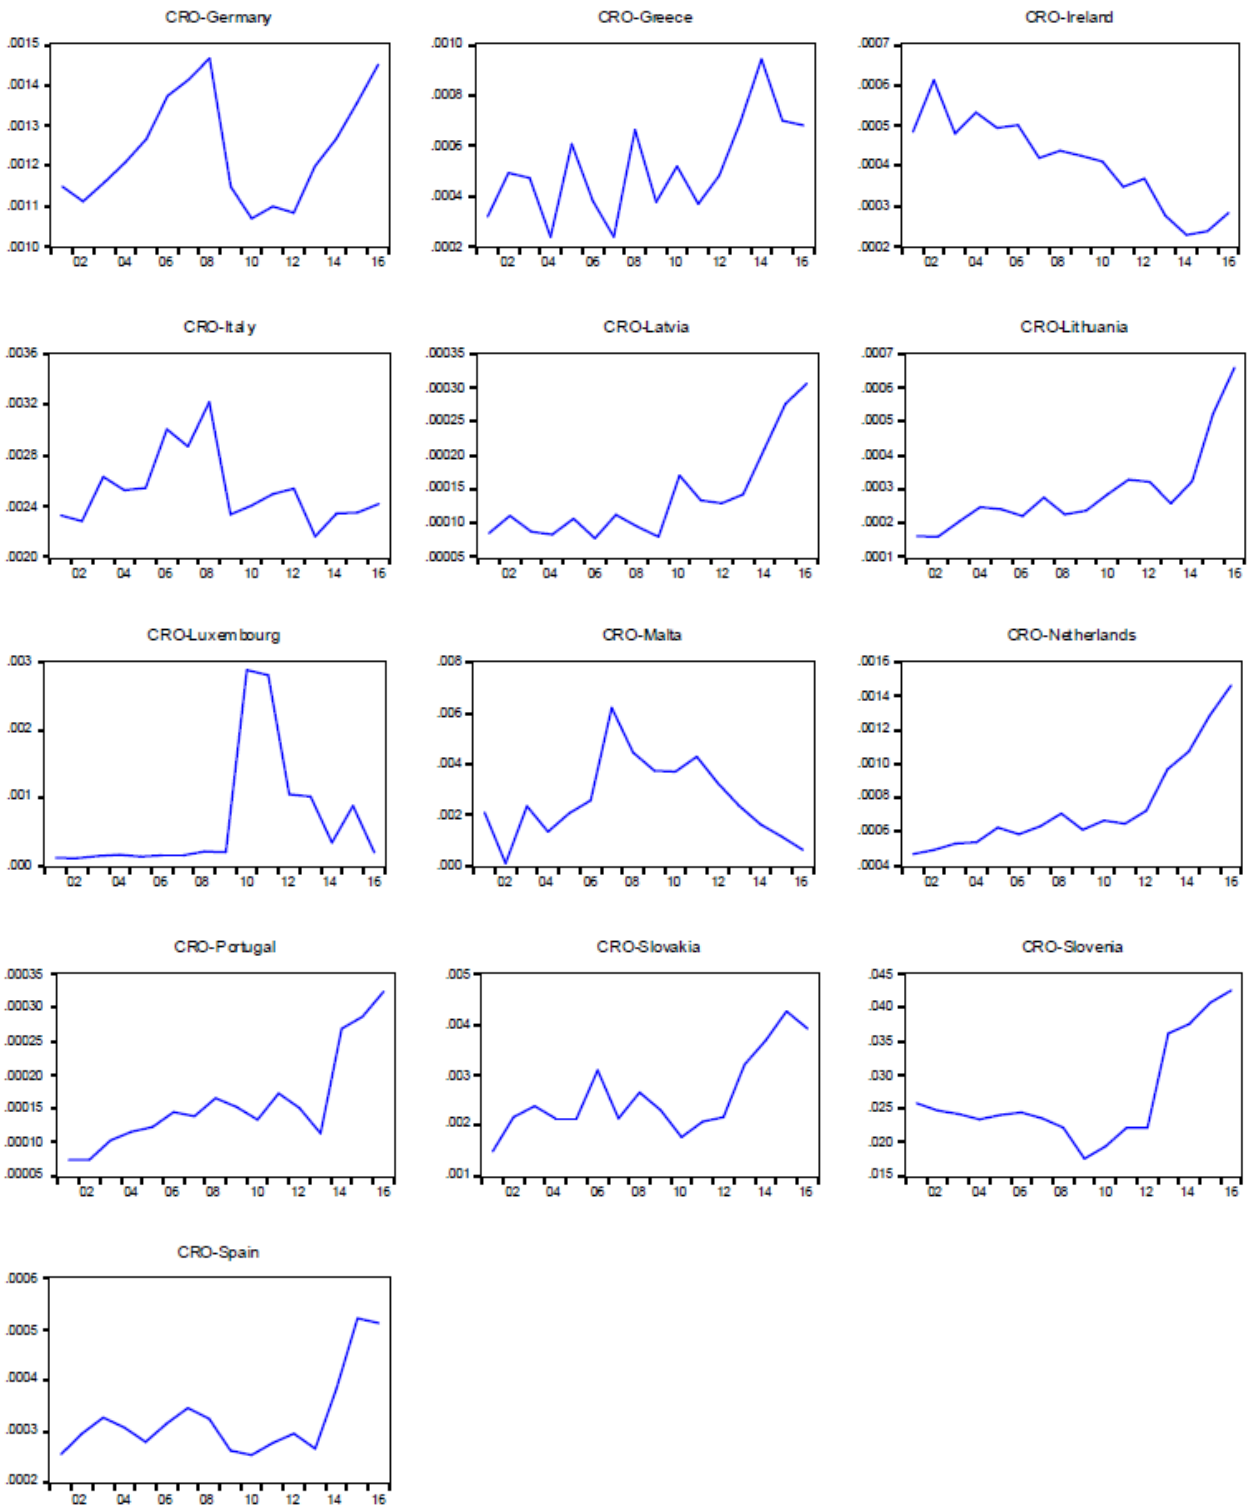

Izvor: Izrada autora (EViews 9)

Iz grafikona 4. vidljivo je da trgovinska integracija Hrvatske sa zemljama eurozone raste do 2008. S pojavom financijske krize 2009. dolazi do snažnog pada trgovinskih tokova, a oporavak slijedi nakon završetka europske dužničke krize 2012. godine.

5.2.4. Sličnost sektorskih struktura

Po uzoru na Krugmana (1991) sličnost sektorskih struktura (SS5) mjeri se sumom apsolutnih razlika bruto dodane vrijednosti sektora između dviju zemalja:

$$SS_{ijt} = \sum_{n=1}^{N} \left| s_{nit} - s_{njt} \right| \quad ,$$

gdje s_{nit} predstavlja bruto dodanu vrijednost sektora *n* zemlje *i* u razdoblju *t* mjerenu udjelom u BDP-u t. Sličnost sektorskih struktura kreće se u intervalu od nula do dva, pri čemu vrijednost dva označava potpuno različite strukture Hrvatske i promatrane zemlje eurozone, a vrijednost nula potpune identične sektorske strukture zemalja. Dakle, viša vrijednost indeksa označava veću razliku u sektorskim strukturama između Hrvatske i zemalja eurozone, tj. veću specijalizaciju u različitim sektorima. Za izvor podataka o bruto dodanoj vrijednosti sektora zemalja koristi se Eurostatova baza podataka. Sektori se sistematiziraju prema NACE Rev.2 klasifikaciji ekonomske aktivnosti koja se sastoji od 21 sektora.

Osim toga, sličnost sektorskih struktura mjeri se bruto dodanom vrijednošću sektora mjerenog udjelom u ukupnoj bruto dodanoj vrijednosti (SS2). Sličnost sektorskih struktura (SS2) kreće se u intervalu od nula do dva, pri čemu niža vrijednost označava sličnije sektorske strukture promatranih zemalja. Za izvor podataka koristi se baza podataka Eurostat.

Konačno, sličnost sektorskih struktura (SS1) mjeri se isto kao i sličnost sektorskih struktura (SS5), ali na višoj razini agregacije (NACE Rev.2 klasifikaciji ekonomske aktivnosti koja se sastoji od 11 sektora). Viša vrijednost (SS1) označava različitije sektorske strukture, a za izvor podataka također se koristi baza podataka Eurostat.

Na grafikonu 5. prikazana je sličnost sektorske strukture Hrvatske sa sektorskim strukturama zemalja eurozone u razdoblju od 2001. do 2016. godine.

Promatrajući sektorsku strukturu na višoj razini agregacije ekonomske aktivnosti, najveći udio bruto dodane vrijednosti u BDP-u Hrvatska u razdoblju od 2001. do 2016. ostvaruje iz sektora industrije (prosječno 17,9%), proizvodnje (prosječno 13%), trgovine, transporta i usluživanja hrane (prosječno 18,3%) te javne administracije, obrane, obrazovanja i ljudskog zdravlja (prosječno 12,7%).

Zbog različite dinamike rasta pojedinih sektora u Hrvatskoj je u razdoblju od 2001. do 2016. došlo do promjena u sektorskoj strukturi. Tako je sektor stručne, znanstvene i tehničke djelatnosti; administrativne i pomoćne uslužne djelatnosti ostvario rast od 3 postotna poena (s 4% na 7% udjela bruto dodane vrijednosti u BDP-u), sektor financijske djelatnosti i djelatnosti osiguranja rast od 1,3 postotna poena (s 4% na 5,3%), a sektor trgovine na veliko i na malo; popravka motornih vozila i motocikla rast od 1,1 postotnog poena (sa 17,8% na 18,9%). Istovremeno, pojedini sektori smanjili su udio bruto dodane vrijednosti u BDP-u - sektor prerađivačke industrije za 2 postotna poena (s 14,7% na 12,7%), sektor poljoprivrede, šumarstva i ribarstva za 1,9 postotnih poena (s 5,3% na 3,4%), a sektor industrije za 1,7 postotnih poena (s 19,4% na 17,7%).

Grafikon 5. Sličnost sektorske strukture Hrvatske i sektorskih struktura zemalja eurozone (SS5)

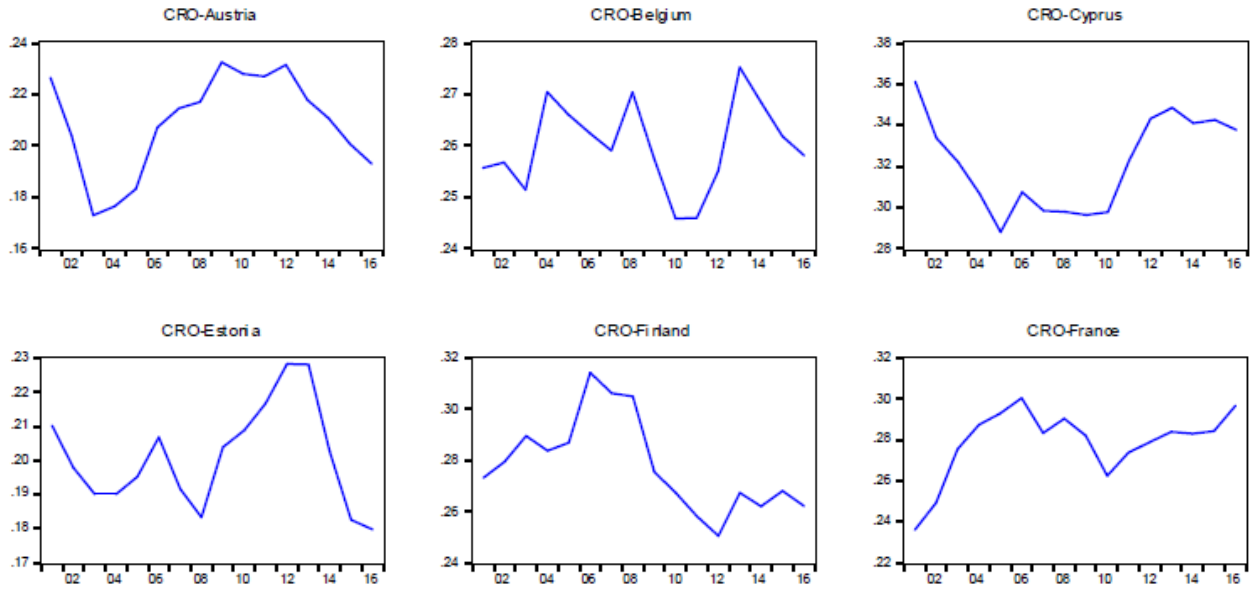

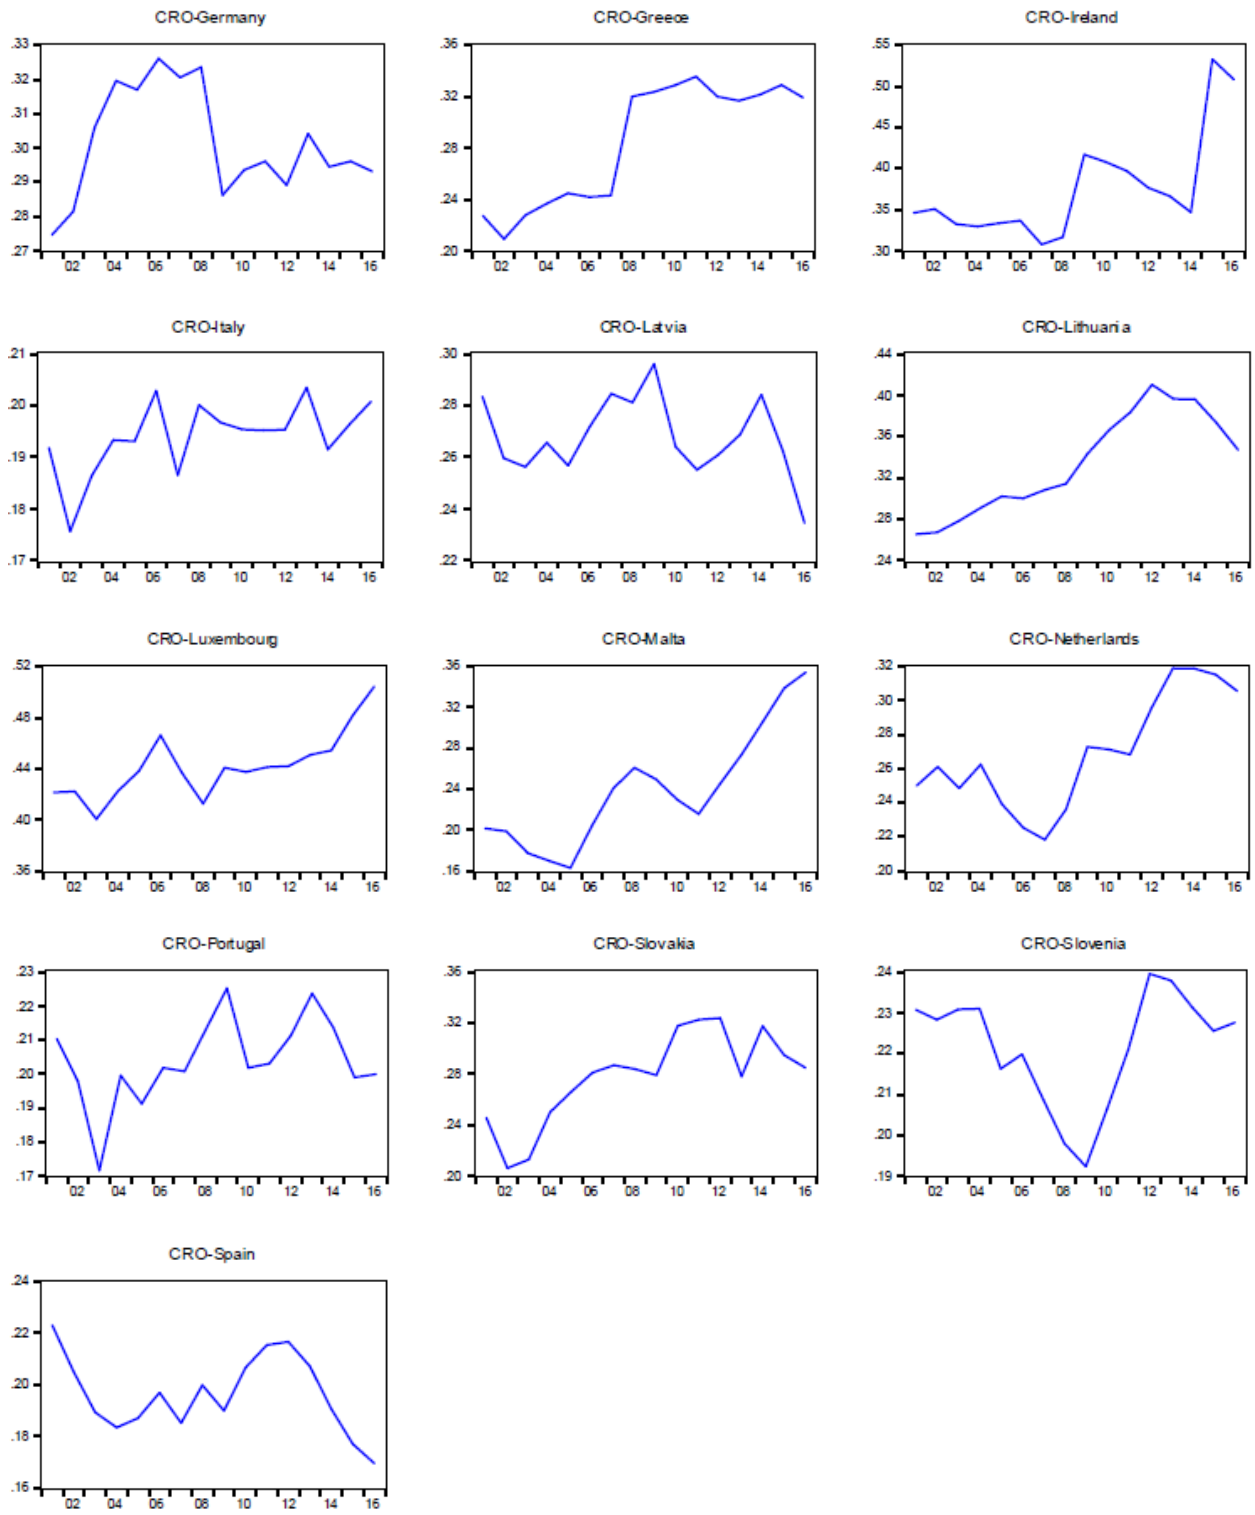

Izvor: Izrada autora (EViews 9)

Iz grafikona 5. vidljivo je da Hrvatska (uspoređujući je sa zemljama eurozone) ima najsličniju sektorsku strukturu s Austrijom, Italijom, Portugalom, Španjolskom i Slovenijom, dok se najviše razlikuje u od sektorske strukture Francuske, Njemačke, Irske, Luksemburga i Latvije. Dodatno, vidljivo je da sektorska struktura Hrvatske u razdoblju prije krize divergira s dijelom zemalja eurozone (Austrija, Njemačka i Francuska) što ukazuje na specijalizaciju zemalja (u različitim sektorima) pod utjecajem snažnih kapitalnih tokova.

5.2.5. Konvergencija fiskalnih politika

Konvergencija fiskalnih politika mjeri se negativnom apsolutnom razlikom strukturnih (ciklički prilagođenih) proračunskih salda po uzoru na Artisa, Fidrmuca i Scharlera (2008) te Inklaara, Jong-A-Pina i De Haana (2008):

$$KFP_{ijt} = -\left|d_{it} - d_{jt}\right| \ ,$$

gdje d_{it} predstavlja udio strukturnog proračunskog salda u BDP-u zemlje *i* u razdoblju *t*.

Darvas, Rose i Szapary (2007), Bower i Gullemineau (2006), Antonakakis i Tondl (2014) te Alimi (2015) konvergenciju fiskalnih politika mjere apsolutnom razlikom ukupnih proračunskih salda u BDP-u. Za razliku od njih, Fonseca, Patureau i Sopraseuth (2010) i Lukmanova i Tondl (2017) konvergenciju fiskalnih politika mjere apsolutnom razlikom udjela primarnih proračunskih salda u BDP-u. Dodatno, Akin (2012) sličnost fiskalnih politika mjeri prosječnom apsolutnom razlikom javnih potrošnji u BDP-ovima zemalja. Korištenjem strukturnog proračunskog salda za indikator fiskalne politike eliminira se problem endogenosti koji proizlazi iz simultanosti, tj. utjecaja poslovnih ciklusa na fiskalne politike zemalja.

Viša vrijednost KFP_{ijt} označava veći stupanj konvergencije fiskalne politike Hrvatske s fiskalnom politikom odabrane zemlje eurozone. Podaci o strukturnim proračunskim saldima zemalja preuzeti su iz MMF-ove baze podatka (International Monetary Fund, World Economic Outlook Database).

Na grafikonu 6. prikazana je konvergencija fiskalne politike Hrvatske s fiskalnim politikama zemalja eurozone u razdoblju od 2001. do 2016. godine. Hrvatska je u 2002. godini ostvarila strukturni proračunski deficit od 2,78%, a isti kontinuirano raste u 2003. i u 2004. godini u kojoj

dostiže 5,37%. Od 2005. do 2007. strukturni proračunski deficit kreće se od 4,52% do 4,82%, da bi se u godinama globalne financijske krize opet povećao do 5,42% (u 2009.). S obzirom na kretanje poslovnog ciklusa Hrvatske koji se nalazi u fazi ekspanzije (inflacijskog jaza outputa) sve do 2008. godine, očigledno je da je hrvatska u razdoblju od 2002. do 2008. godine provodila ekspanzivnu procikličku politiku.

Grafikon 6. Konvergencija fiskalne politike Hrvatske sa zemljama eurozone

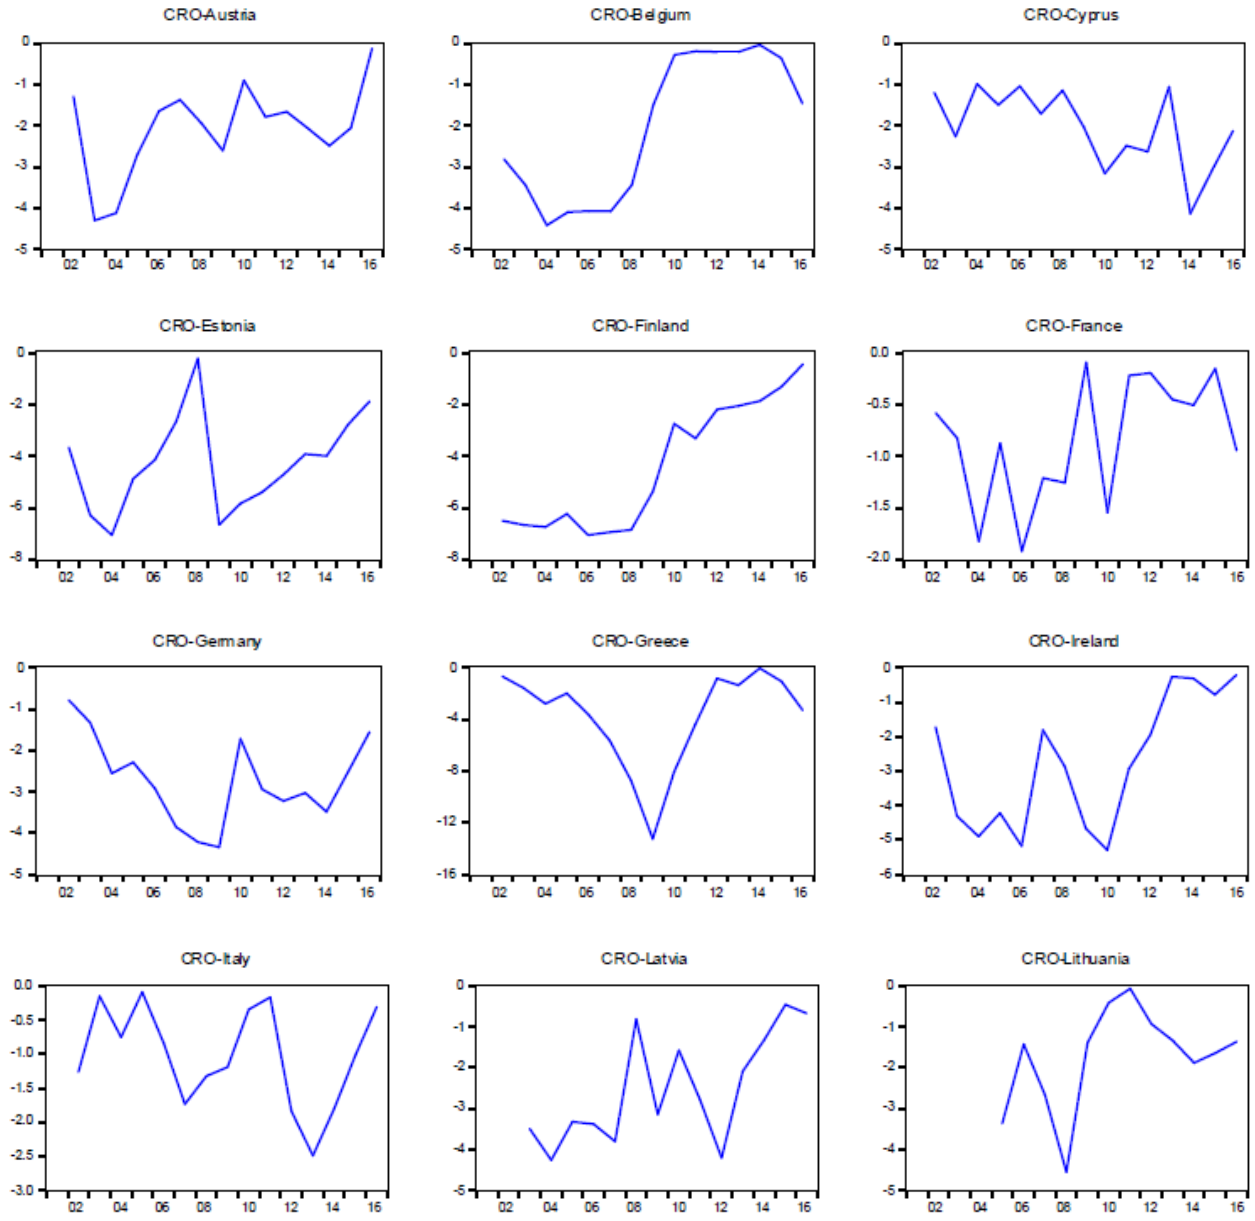

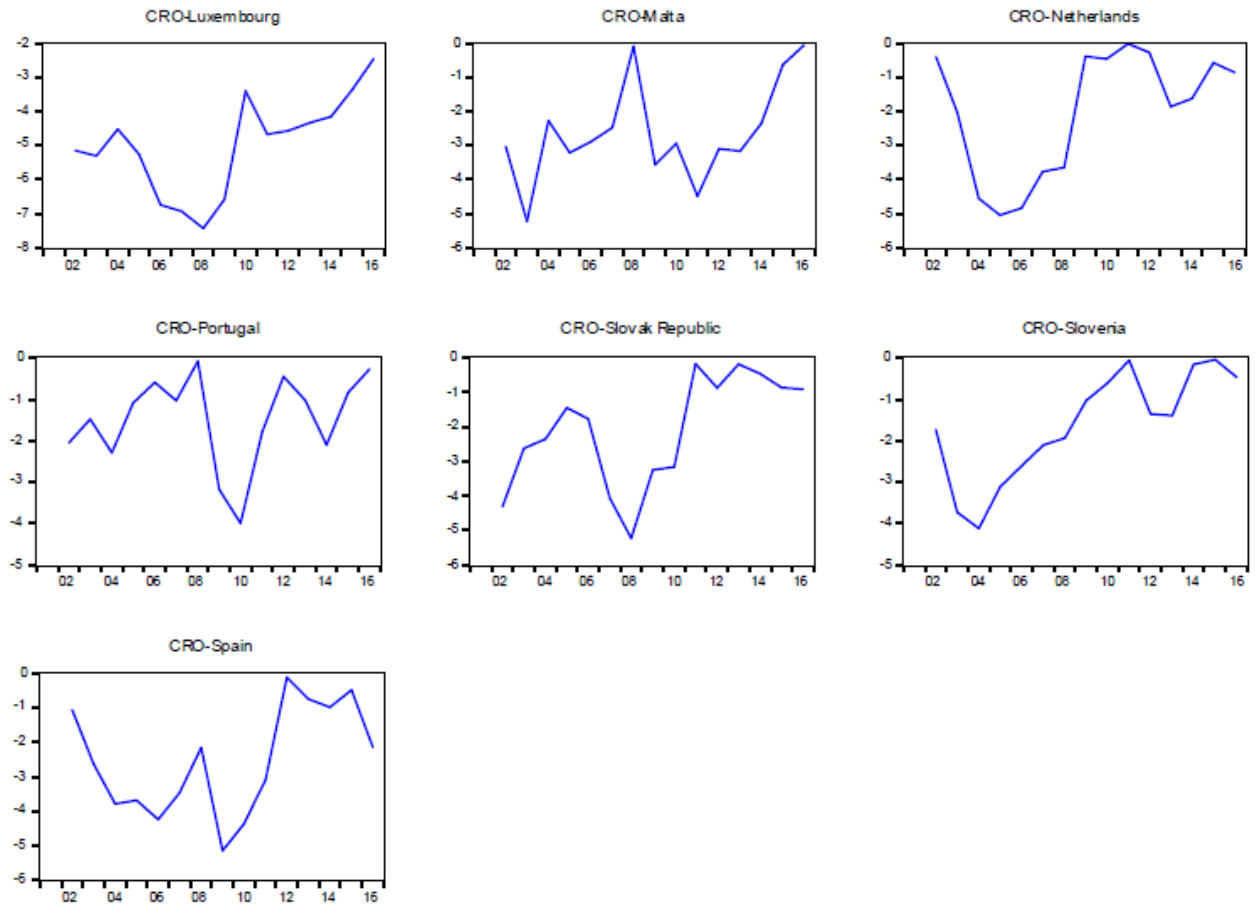

Izvor: Izrada autora (EViews 9)

Slično kao i Hrvatska, većina zemalja eurozone je u razdoblju od 2002. do 2008. godine imala deficit strukturnog proračunskog salda (osim Finske i Luksemburga koji imaju suficit). Međutim, razine strukturnih proračunskih deficita zemalja eurozone se značajno razlikuju. Dio zemalja ima niže stope strukturnog proračunskog deficita - Estonija (prosječni strukturni deficit 0,41%), Belgija (prosječni strukturni deficit 0,77%), Nizozemska (prosječni strukturni deficit 1,07%) i Slovenija (prosječni strukturni deficit 1,78%); a s druge strane dio zemalja ima poprilično visoke strukturne deficite – Grčka (prosječni strukturni deficit 8,11%), Latvija (prosječni strukturni deficit 5,42%) i Portugal (prosječni strukturni deficit 5,31%). Hrvatska u promatranom razdoblju ima prosječni strukturni deficit 4,54% što je svrstava u skupinu zemalja s visokim stopama proračunskog deficita. Takva razina proračunskog deficita uzrokuje snažno gomilanje javnog duga.

Iz grafikona 6. vidljivo je da najveći stupanj konvergencije fiskalnih politika (najmanju razliku između strukturnih deficita) Hrvatska u razdoblju od 2002. do 2008. godine ostvaruje s Italijom (prosječno 0,88 postotna poena), Francuskom (prosječno 1,22 postotna poena), Portugalom (prosječno 1,23 postotna poena) te Ciprom (prosječno 1,40 postotnih poena), dok se najveći jaz između strukturnih deficita ostvaruje s Finskom (prosječno 6,72 postotna poena), Luksemburgom (prosječno 5,91 postotni poen), Estonijom (prosječno 4,13 postotnih poena) i Grčkom (prosječno 3,57 postotnih poena).

U 2009. godini Hrvatska ostvaruje strukturni deficit od 5,42%, a isti se kontinuirano smanjuje sve do 2016. u kojoj iznosi 0,96%. U navedenom razdoblju zemlje eurozone također su smanjile svoje strukturne proračunske deficite, međutim dio zemalja i dalje ostvaruje visoke strukturne proračunske deficite: Grčka (prosječni strukturni deficit 5,64%), Irska (prosječni strukturni deficit 5,03%), Slovenija (prosječni strukturni deficit 4,91%) te Slovačka (prosječni strukturni deficit 4,38%). S prosječnim strukturnim proračunskim deficitom od 3,24% u promatranom razdoblju Hrvatska spada u skupinu zemalja s višim strukturnim proračunskim deficitom. U tom razdoblju smanjuje se jaz između strukturnog deficita Hrvatske i zemalja eurozone što znači da dolazi do snažne konvergencije fiskalne politike Hrvatske s fiskalnim politikama promatranih zemalja. U razdoblju od 2009. do 2016. godine razlika strukturnog deficita Hrvatske i Belgije iznosi prosječno 0,52 postotna poena, prosječna razlika sa strukturnim deficitom Francuske također 0,52 postotna poena, prosječna razlika sa strukturnim deficitom Slovenije 0,63 postotna poena, a prosječna razlika sa strukturnim deficitom Slovačke 1,23 postotna poena. S druge strane, najveću razliku između strukturnih deficita u promatranom razdoblju Hrvatska ostvaruje s Estonijom (prosječno 4,40 postotnih poena), Luksemburgom (prosječno 4,19 postotnih poena), Grčkom (prosječno 4,04 postotna poena) te Ciprom (prosječno 2,59 postotnih poena). U Hrvatskoj 2009. godine dolazi do kontrakcije poslovnog ciklusa (pojave deflacijskog jaza outputa) koja traje sve do 2016. godine, a u tom razdoblju fiskalna politika Hrvatske bila je ekspanzivnog anticikličkog karaktera.

5.3. Prostorna i vremenska definicija uzorka

Ekonometrijska analiza provedena je na prostornom uzorku koji obuhvaća Hrvatsku i zemlje eurozone: Austriju, Belgiju, Cipar, Estoniju, Finsku, Francusku, Grčku, Irsku, Italiju, Latviju, Litvu, Luksemburg, Nizozemsku, Njemačku, Maltu, Portugal, Slovačku, Sloveniju i Španjolsku. Zbog specifičnosti istraživanja, kojim se analizira Hrvatska sa zemljama Eurozone u obliku parova zemalja, prostorna dimenzija obuhvaća 19 bilateralnih opažanja (Hrvatska sa svakom zemljom eurozone).

S obzirom na to da podaci za Hrvatsku čine neizostavni dio kod konstrukcije svih varijabli, ograničenost podataka za Hrvatsku definira vremensku dimenziju uzorka. Uzimajući u obzir navedenu činjenicu, vremenska dimenzija uzorka obuhvaća razdoblje od 2001. do 2016. godine jer je većina podataka za Hrvatsku dostupna tek od 2001. godine. Dakle, uzorak sačinjava prostorna dimenzija od 19 bilateralnih opažanja i vremenska dimenzija od 16 godina (2001. – 2016.), tj. sastoji se od maksimalno 304 (n=19*16) opažanja.

Za pojedine zemlje nedostaju podaci o stanju dolaznih izravnih stranih investicija iz Hrvatske za dio promatranog razdoblja (Finska, Grčka, Litva, Latvija i Portugal), realnim stopama povrata na desetogodišnje obveznice (Slovenija za 2001. te Estonija za cjelokupno razdoblje) te strukturnim deficitima zemalja (Hrvatska za 2001. te Litva i Latvija za dio razdoblja). U skladu s time kod pojedinih panel modela smanjen je ukupni broj opažanja ovisno o korištenim indikatorima.

5.4. Rezultati istraživanja

U ovom potpoglavlju prikazana je deskriptivna statistika varijabli, korelacijska matrica i dijagrami rasipanja iz kojih su vidljivi osnovni odnosi između varijabli. Osim toga, napravljena je panel analiza putem koje su empirijski potvrđeni različiti kanali utjecaja financijske integracije na usklađivanje poslovnih ciklusa Hrvatske sa zemljama eurozone.

5.4.1. Deskriptivna statistika

Deskriptivnom statistikom daje se uvid u opća obilježja promatranog skupa parova zemalja. Među opća obilježja uključeni su: pokazatelji srednje vrijednosti - aritmetička sredina (engl. mean) i medijan; raspon vrijednosti varijabli - maksimalna i minimalna vrijednost; standardna devijacija; mjera asimetričnosti (engl. skewness); i mjera zaobljenosti (engl. curtosis). U sklopu deskriptivne statistike također je prikazan Jarque-Bera test normalnosti distribucije te ukupni broj opažanja po pojedinoj varijabli. U tablici 2. prikazana je deskriptivna statistika korištenih varijabli.

Tablica 2. Deskriptivna statistika

	BCS	FI1	FI3	GDPPC1	GDPPC2	GDPPROD
Mean	0.676844	0.003448	1.831358	16526.97	2.73E+08	2.14E+10
Median	0.889792	0.000348	1.441667	13150.00	2.48E+08	7.62E+09
Maximum	1.000000	0.047076	16.36917	73200.00	9.45E+08	1.31E+11
Minimum	-1.822313	-2.98E-06	0.019167	0.000000	47600000	1.93E+08
Std. Dev.	0.504786	0.006636	1.568247	15380.68	1.66E+08	3.20E+10
Skewness	-2.616017	2.703750	3.480104	1.810851	1.738560	1.763762
Kurtosis	10.79717	12.40559	28.81403	6.994208	7.024383	4.971401
Jarque-Bera	1116.820	1216.298	8547.920	368.2254	358.2896	206.8447
Probability	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
Sum	205.7604	0.855172	525.5998	5024200.	8.31E+10	6.50E+12
Sum Sq. Dev.	77.20717	0.010877	703.3881	7.17E+10	8.33E+18	3.10E+23
Observations	304	248	287	304	304	304

	KFP	SS1	SS2	SS5	TI1	TI2
Mean	-2.517875	25.52072	0.304572	0.271346	0.002430	3.17E-06
Median	-2.083000	23.50000	0.295963	0.263270	0.000494	7.10E-07
Maximum	-0.013000	65.50000	0.608963	0.532859	0.042555	4.14E-05
Minimum	-13.25800	9.000000	0.171925	0.162914	5.46E-05	7.17E-08
Std. Dev.	1.968247	9.900535	0.082661	0.070173	0.006167	7.04E-06
Skewness	-1.184454	1.061291	0.993774	1.017366	4.313648	3.760445
Kurtosis	5.586392	4.303521	4.033371	4.047423	22.37981	16.87317
Jarque-Bera	144.0260	78.59064	63.56391	66.33823	5700.091	3154.364
Probability	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
Sum	-707.5230	7758.300	92.59001	82.48920	0.738751	0.000965
Sum Sq. Dev.	1084.719	29700.24	2.070372	1.492038	0.011525	1.50E-08
Observations	281	304	304	304	304	304

Izvor: Izrada autora

Na promatranom uzorku od 2001. do 2016. godine koji se sastoji od 304 opažanja, prosječna vrijednost usklađenosti poslovnih ciklusa (BCS) Hrvatske sa zemljama eurozone iznosi 0,677. Vrijednost standardne devijacije (0,505) označava značajna odstupanja od prosječne vrijednosti usklađenosti poslovnih ciklusa. To znači da usklađenost poslovnog ciklusa Hrvatske sa zemljama eurozone značajno varira ovisno o zemlji eurozone s kojom se promatra. Navedeno potvrđuje i vrijednost usklađenosti poslovnih ciklusa koja se kreće u rasponu od -1,822 do 1. Na temelju koeficijenta asimetričnosti (-2,616) i zaobljenosti (10,797) te rezultata Jarque-Bera testa (1.116,82) može se zaključiti da distribucija nije normalnog oblika.

Prosječna vrijednost varijable financijska integracija (FI1) iznosi 0,003448, pri čemu standardna devijacija iznosi 0,006636. Vrijednost se kreće u rasponu od -2,98E-06 do 0,047076 što ukazuje da financijska integracija Hrvatske značajno varira u odnosu na pojedine zemlje eurozone. Medijan navedene varijable (0,000348) upućuje na to da Hrvatska ima nižu razinu financijske integracije s dijelom zemalja eurozone. Nenormalnost distribucije promatrane varijable potvrđena je s rezultatom Jarque-Bera testa (1.216,30) te koeficijentom asimetričnosti (2,704) i koeficijentom zaobljenosti (12,406).

Financijska integracija (FI3) obuhvaća 287 opažanja s prosječnom vrijednošću 1,831 pri čemu standardna devijacija iznosi 1,568. Vrijednost financijske integracije kreće se u rasponu od 0,019 do 16,369. Koeficijent asimetričnosti (3,480) i koeficijent zaobljenosti (28,814) te rezultat Jarque-Bera testa (8.547,92) potvrđuju da distribucija nije normalnog oblika.

Podaci o prosječnoj vrijednosti razvijenosti zemalja (GDPPC1), njezinoj standardnoj devijaciji i kretanju vrijednosti (od 0,000 do 73.200,00) potvrđuju da unutar same eurozone postoji značajna razlika u stupnju razvijenosti zemalja. Koeficijent asimetričnosti (1,811) i koeficijent zaobljenosti (6,994) te rezultat Jarque-Bera testa (368,23) potvrđuju nenormalnost distribucije promatrane varijable.

Varijabla razvijenost zemalja (GDPPC2) ima prosječnu vrijednost 2,73E+08, standardnu devijaciju 1,66E+08, a njezina vrijednost kreće se u rasponu od 47.600.000,00 do 9,45E+08. Slično kao i kod varijable GDPPC1, na temelju navedenih vrijednosti može se zaključiti da unutar eurozone postoji značajna razlika u stupnju razvijenosti zemalja. Koeficijent asimetričnosti

(1,739) i koeficijent zaobljenosti (7,024) te rezultat Jarque-Bera testa (358,29) potvrđuju da distribucija nije normalnog oblika.

Podaci o prosječnoj vrijednosti varijable veličine zemalja (GDPprod), standardnoj devijaciji i kretanju vrijednosti upućuju da se zemlje eurozone značajno razlikuju po veličini (ekonomskoj snazi), te da s različitim intenzitetom utječu na hrvatsku ekonomiju. Koeficijent asimetričnosti (1,764) i koeficijent zaobljenosti (4,971) te rezultat Jarque-Bera testa (206,85) potvrđuju nenormalnost distribucije.

Konvergencija fiskalnih politika (KFP) obuhvaća 281 opažanje s prosječnom vrijednošću -2,518, pri čemu standardna devijacija iznosi 1,968. Vrijednost konvergencije fiskalnih politika kreće se u rasponu od -13,258 do -0,013. Navedeni podaci ukazuju da postoje velike razlike u vođenju fiskalnih politika između zemalja eurozone. Koeficijent asimetričnosti (1,184) i koeficijent zaobljenosti (5,586) te rezultat Jarque-Bera testa (144,03) potvrđuju da distribucija nije normalnog oblika.

Deskriptivna statistika varijable sličnost sektorskih struktura (SS1) pokazuje da je sektorska struktura Hrvatske slična s pojedinim zemljama eurozone, dok se s druge strane drastično razlikuje od dijela zemalja eurozone. Koeficijent asimetričnosti (1,06) i koeficijent zaobljenosti (4,304) te rezultat Jarque-Bera testa (78,59) potvrđuju nenormalnost distribucije promatrane varijable.

Na temelju prosječne vrijednosti (0,305), standardne devijacije (0,083) i kretanja vrijednosti (od 0,172 do 0,609) varijable sličnost sektorskih struktura (SS2) može se potvrditi zaključak koji vrijedi za varijablu SS1 i na nižoj razini agregacije sektorske aktivnosti. Koeficijent asimetričnosti (0,994) i koeficijent zaobljenosti (4,033) te rezultat Jarque-Bera testa (63,56) potvrđuju da distribucija nije normalnog oblika.

Rezultati deskriptivne statistike varijable sličnost sektorskih struktura (SS5) slični su rezultatima deskriptivne statistike varijabli SS1 i SS2 čime se također potvrđuju njihovi zaključci. Na promatranom uzorku od 2001. do 2016. godine koji se sastoji od 304 opažanja prosječna vrijednost sličnosti sektorskih struktura (SS5) iznosi 0,271 sa standardnom devijacijom od 0,070.

Vrijednost sličnosti sektorskih struktura kreće se u rasponu od 0,163 do 0,533. Koeficijent asimetričnosti (1,017) i koeficijent zaobljenosti (4,047) te rezultat Jarque-Bera testa (66,34) potvrđuju nenormalnost distribucije promatrane varijable.

Rezultati deskriptivne statistike za varijablu trgovinska integracija (TI1) potvrđuju da Hrvatska ostvaruje znatno manju relativnu robnu razmjenu s dijelom zemalja eurozone. Koeficijent asimetričnosti (4,314) i koeficijent zaobljenosti (22,380) te rezultat Jarque-Bera testa (5.700,09) potvrđuju da distribucija nije normalnog oblika.

Prosječna vrijednost varijable trgovinska integracija (TI2) iznosi 3,17E-06 sa standardnom devijacijom od 7,04E-06. Njezina vrijednost kreće se u rasponu od 7,17E-08 do 4,14E-05 što potvrđuje zaključke varijable TI1. Koeficijent asimetričnosti (3,760) i koeficijent zaobljenosti (16,873) te rezultat Jarque-Bera testa (3.154,36) potvrđuju nenormalnost distribucije promatrane varijable.

S obzirom na to da promatrane nezavisne varijable imaju nenormalnu distribuciju, iste će se logaritmirati s ciljem postizanja normalnosti distribucije.

Iako panel modeli, za razliku od presječnih (engl. cross-sectional) podataka ili vremenskih nizova, rjeđe pate od problema multikolinearnosti nezavisnih varijabli, ipak je potrebno testirati postoji li navedeni problem u konkretnom slučaju. U svrhu testiranja multikolinearnosti napravljena je korelacijska matrica (prikazana u tablici 3.). Iz korelacijske matrice je vidljivo da postoji srednje jaka korelacija između nezavisnih varijabli: logFI1-logTI1 (0,518), logFI-logTI2 (0,479), logGDPPC1-logGDPprod (0,466), logTI1-logSS2 (-0,553), logTI2-logSS2 (-0,585), logTI1-logSS5(-0,571), te logTI2-logSS5 (-0,611).

Tablica 3. Korelacijska matrica

	BCS	LOGFI1	LOGFI3	LOGGDPPC1	LOGGDPPC2	LOGGDPPRO
BCS	1.000000	-0.005861	-0.153526	-0.005207	-0.005031	0.041818
LOGFI1	-0.005861	1.000000	0.046207	0.409867	0.420854	-0.104381
LOGFI2	0.034698	0.852332	0.012722	0.305811	0.297995	-0.248801
LOGFI3	-0.153526	0.046207	1.000000	0.209041	0.171483	0.150956
LOGGDPPC1	-0.005207	0.409867	0.209041	1.000000	0.927521	0.465861
LOGGDPPC2	-0.005031	0.420854	0.171483	0.927521	1.000000	0.426265
LOGGDPPRO	0.041818	-0.104381	0.150956	0.465861	0.426265	1.000000
LOGKFP	0.188945	-0.003502	0.161449	-0.057847	-0.122770	0.119051
LOGSS1	-0.191733	0.126711	0.106260	0.196254	0.297945	-0.226773
LOGSS2	-0.182495	-0.079003	0.130730	0.069246	0.228426	-0.236113
LOGSS5	-0.177647	-0.093120	0.145572	0.082313	0.242288	-0.191028
LOGTI1	0.138066	0.518117	-0.089211	-0.206497	-0.297129	-0.167216
LOGTI2	0.112634	0.479391	-0.076603	-0.153093	-0.272448	-0.101098

	LOGKFP	LOGSS1	LOGSS2	LOGSS5	LOGTI1	LOGTI2
BCS	0.188945	-0.191733	-0.182495	-0.177647	0.138066	0.112634
LOGFI1	-0.003502	0.126711	-0.079003	-0.093120	0.518117	0.479391
LOGFI2	-0.011746	0.097750	-0.087121	-0.107982	0.519791	0.463532
LOGFI3	0.161449	0.106260	0.130730	0.145572	-0.089211	-0.076603
LOGGDPPC1	-0.057847	0.196254	0.069246	0.082313	-0.206497	-0.153093
LOGGDPPC2	-0.122770	0.297945	0.228426	0.242288	-0.297129	-0.272448
LOGGDPPRO	0.119051	-0.226773	-0.236113	-0.191028	-0.167216	-0.101098
LOGKFP	1.000000	-0.130400	-0.107796	-0.093705	0.141728	0.139838
LOGSS1	-0.130400	1.000000	0.898350	0.878571	-0.393984	-0.378313
LOGSS2	-0.107796	0.898350	1.000000	0.991790	-0.552735	-0.584548
LOGSS5	-0.093705	0.878571	0.991790	1.000000	-0.570864	-0.611031
LOGTI1	0.141728	-0.393984	-0.552735	-0.570864	1.000000	0.962406
LOGTI2	0.139838	-0.378313	-0.584548	-0.611031	0.962406	1.000000

Izvor: Izrada autora

Zbog navedene korelacije između nezavisnih varijabli napravljena je analiza faktora inflacije varijance (engl. variance inflation factor) nezavisnih varijabli u svrhu dodatnog testiranja potencijalnog problema multikolinearnosti nezavisnih varijabli. Vrijednost faktora inflacije varijance pokazuje stupanj povećanja standardne pogreške zbog korelacije jedne nezavisne varijable s drugim nezavisnim varijablama u modelu (tj. koliko se varijanca procijenjenog regresijskog koeficijenta povećala zbog kolinearnosti). Vrijednost faktora inflacije varijance veća od 5 smatra se indikatorom multikolinearnosti. U tablici 4. prikazana je vrijednost faktora inflacije varijance nezavisnih varijabli za pet modela.

Tablica 4. Analiza faktora inflacije varijance nezavisnih varijabli

Variable	VIF	1/VIF
logTI1	1.92	0.519563
logFI1	1.89	0.529596
logSS1	1.17	0.856219
lag_BCS4	1.05	0.948366
logKFP	1.05	0.952663
Mean VIF	1.42	

Variable	VIF	1/VIF
logTI1	2.02	0.496098
logFI1	1.81	0.553844
logSS2	1.19	0.839273
lag_BCS4	1.06	0.944559
logKFP	1.04	0.957842
Mean VIF	1.42	

Variable	VIF	1/VIF
logTI1	2.05	0.486842
logFI1	1.81	0.552352
logSS5	1.21	0.826099
lag_BCS4	1.06	0.947296
logKFP	1.05	0.954374
Mean VIF	1.44	

Variable	VIF	1/VIF
logSS5	1.17	0.857865
logTI1	1.10	0.912481
lag_BCS4	1.06	0.942717
logKFP	1.04	0.962944
logFI3	1.03	0.968420
Mean VIF	1.08	

Variable	VIF	1/VIF
logTI2	1.91	0.524516
logFI1	1.65	0.607769
logSS5	1.25	0.797799
lag_BCS4	1.06	0.945845
logKFP	1.03	0.974476
Mean VIF	1.38	

Izvor: Izrada autora

Iz tablice 4. je vidljivo da je vrijednost faktora inflacije varijance kod svih modela značajno manja od 5 (prosječna vrijednost u modelima kreće se od 1,08 do 1,44) što potvrđuje da multikolinearnost među nezavisnim varijablama ne dovodi u pitanje pouzdanost modela.

Prije provođenja ekonometrijske panel analize, napravljeni su dijagrami rasipanja opažanja s procijenjenim regresijskim pravcem (prikazani na grafikonu 7.) iz kojih je vidljiv međuodnos usklađenosti poslovnih ciklusa (zavisne varijable) i nezavisnih varijabli (financijske integracije, trgovinske integracije, sličnosti sektorskih struktura i konvergencije fiskalnih politika). Iako iz

dijagrama rasipanja nije moguće zaključivati o uzročno-posljedičnom odnosu promatranih varijabli, može se opisati smjer i jakost linearne veze dviju varijabli što omogućava osnovni uvid u prirodu odnosa.

Iz dijagrama rasipanja vidljivo je da regresijski pravac između financijske integracije (logFI1) i usklađenosti poslovnih ciklusa (BCS) nema nagib što znači da ne postoji okom vidljiva korelacija između financijske integracije (logFI1) i usklađenosti poslovnih ciklusa (BCS). Slaba povezanost indicira da kapitalni kanal nije dovoljno snažan za usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone. Dijagrami rasipanja FI1-BCS Hrvatske sa svakom zemljom eurozone pojedinačno prikazani su u prilogu 2.

Kad se financijska integracija mjeri apsolutnom razlikom povrata na desetogodišnje obveznice (logFI3) vidljivo je da postoji negativan regresijski pravac koji (zbog načina mjerenja logFI3) označava snažnu pozitivnu linearnu vezu između financijske integracije (logFI3) i usklađenosti poslovnih ciklusa (BCS). Navedeno indicira da konvergencija realnih stopa povrata na desetogodišnje obveznice Hrvatske prema zemljama eurozone (porast financijske integracije) potiče (pozitivno utječe na) usklađivanje poslovnog ciklusa Hrvatske s poslovnim ciklusima zemalja eurozone. Također, pozitivna linearna veza znači da u situaciji "pucanja" kreditnog kanala (s pojavom krize) dolazi do divergencije poslovnog ciklusa Hrvatske od poslovnih ciklusa zemalja eurozone. Dijagrami rasipanja FI3-BCS Hrvatske sa svakom zemljom eurozone pojedinačno prikazani su u prilogu 3.

Dalje, iz dijagrama rasipanja vidljiv je pozitivan regresijski pravac između trgovinske integracije mjerene udjelom bilateralnih robnih tokova u BDP-u (logTI1) i usklađenosti poslovnih ciklusa (BCS) što znači da postoji snažna linearna veza između trgovinske integracije i usklađenosti poslovnog ciklusa Hrvatske s poslovnim ciklusima zemalja eurozone. To ukazuje na važnost trgovinskih tokova za transmisiju poslovnih ciklusa promatranih zemalja. Regresijski pravac ima sličan nagib kad se trgovinska integracija mjeri udjelom bilateralnih robnih tokova u ukupnim robnim tokovima (logTI2).

Grafikon 7. Dijagrami rasipanja s procijenjenim regresijskim pravcem

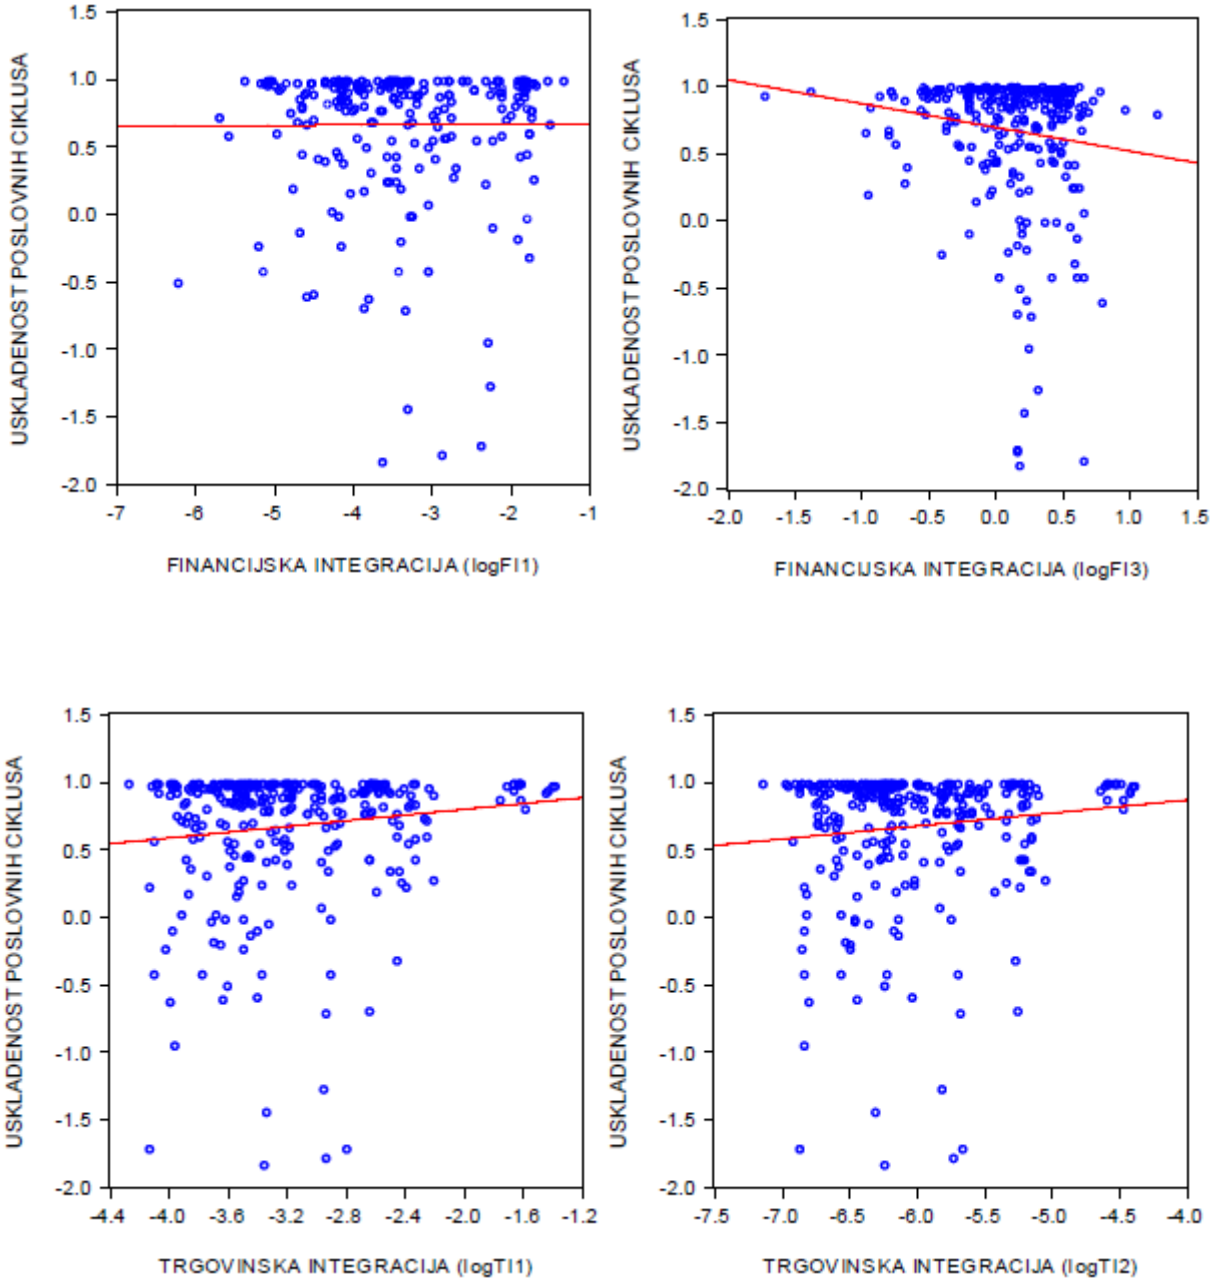

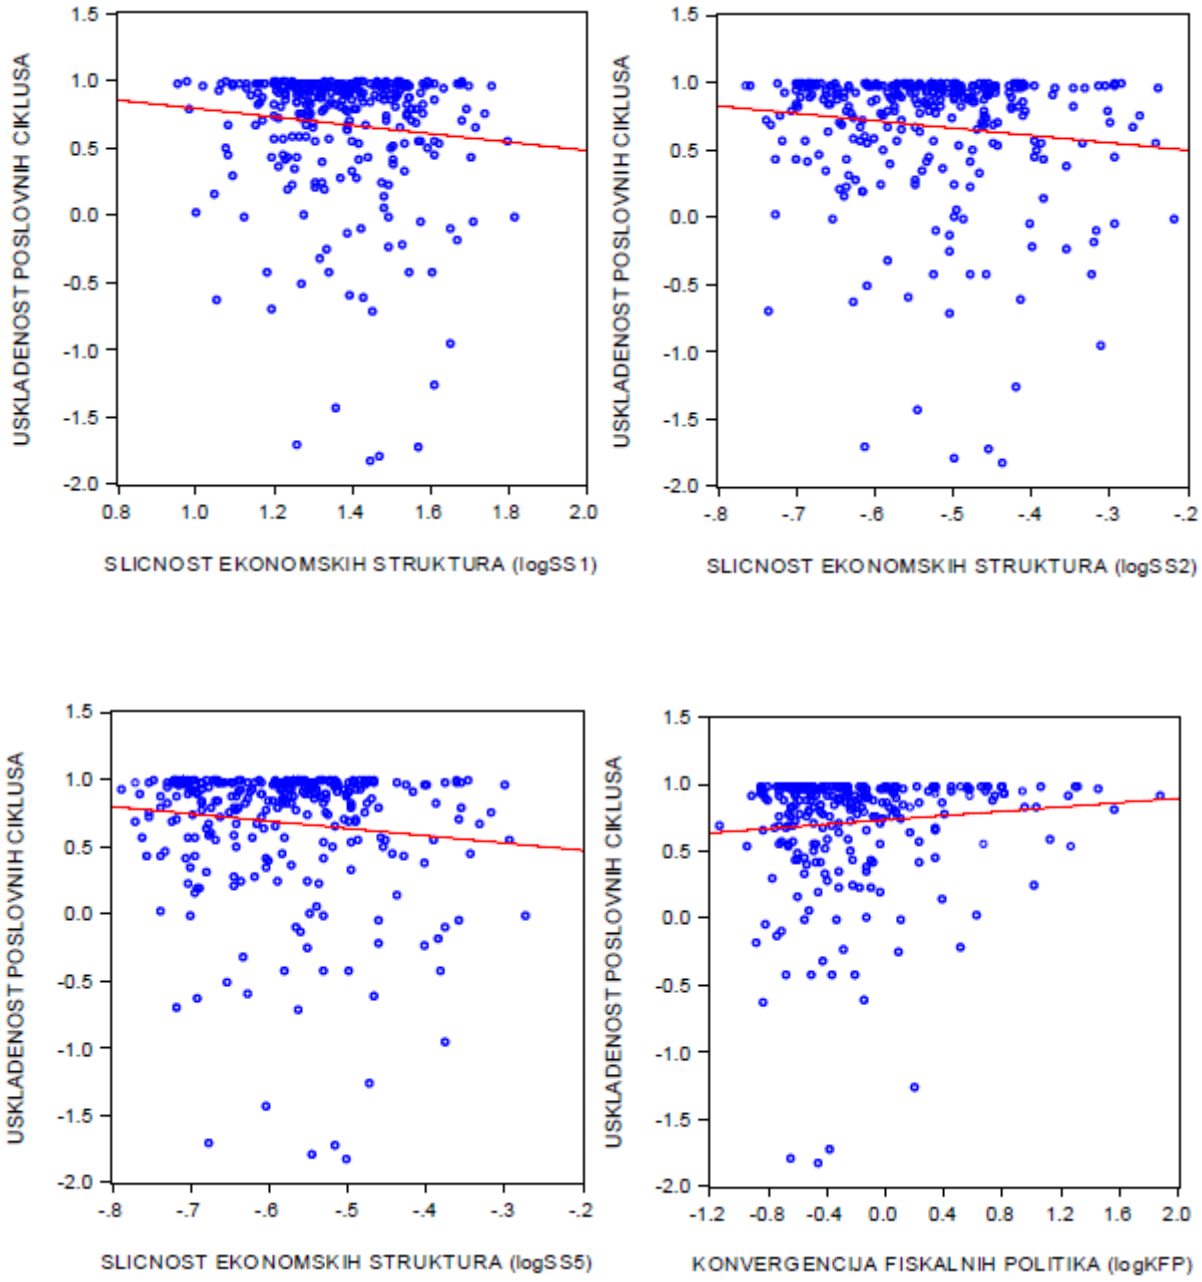

Izvor: Izrada autora (EViews 9)

Iz dijagrama rasipanja vidljivo je da postoji negativan regresijski pravac između sličnosti sektorskih struktura i usklađenosti poslovnih ciklusa. Regresijski pravac ne mijenja značajno nagib neovisno o načinu mjerenja sličnosti sektorskih struktura (logSS1, logSS2 i logSS5), tj. ne ovisi o tome na kojoj razini agregacije sektorskih struktura zemalja se promatra odnos između

promatranih varijabli. S obzirom na način mjerenja sličnosti sektorskih struktura potvrđuje se snažna pozitivna linearna veza između usklađenosti poslovnog ciklusa Hrvatske sa zemljama eurozone i sličnosti njihovih sektorskih struktura. Navedeno indicira da sličnije sektorske strukture zemalja smanjuju rizik od pojave idiosinkratskih šokova, tj. da zemlje sa sličnijim sektorskim strukturama imaju usklađenije poslovne cikluse.

Konačno, konvergencija fiskalnih politika (logKFP) pozitivno je linearno povezana sa stupnjem usklađenosti poslovnih ciklusa jer regresijski pravac ima pozitivan nagib. Iz toga se može pretpostaviti da divergentne fiskalne politike Hrvatske i zemalja eurozone predstavljaju izvor idiosinkratskih fiskalnih šokova koji smanjuju usklađenost njihovih poslovnih ciklusa, što indicira da su fiskalne politike procikličkog karaktera.

5.4.2. Ekonometrijska panel analiza

Prikupljeni podaci sadrže prostornu i vremensku komponentu što omogućava da se parametri modela procijene korištenjem ekonometrijske panel analize. U usporedbi s presječnim podacima (engl. cross-sectional) panel podaci su privlačniji jer sadrže mnogo više informacija što omogućava veću preciznost u procjeni (Hoechle, 2007). Osim toga, panel podaci mogu umanjiti efekt pristranosti parametara (koji se pojavljuje zbog nedostajućih podataka), a procjenitelji u panelima robusniji su na nepotpunu specifikaciju modela.

Procjena parametara modela u svrhu testiranja postavljenih istraživačkih hipoteza izvršena je putem statičkog panela s fiksnim učinkom čija jednadžba glasi:

$$y_{it} = \alpha_i + \beta_1 x_{it1} + \beta_2 x_{it2} + \ldots + \beta_K x_{itK} + \varepsilon_{it};\ i = 1, \ldots N,\ t = 1, \ldots, T,$$

gdje N označava broj jedinica promatranja, T broj vremenskih perioda, $x_{itK}=1,\ldots,K$ vrijednost k-te nezavisne varijable, i-te jedinice promatranja u vremenskom razdoblju t. Parametar α_i je konstantni član različit za svaku jedinicu promatranja, $\beta_1,\ldots,\beta_K$ su parametri koje treba procijeniti. Dalje, ε_{it} predstavlja grešku procjene i-te jedinice promatranja u trenutku t. Pretpostavlja se da su ε_i nezavisno i identično distribuirane slučajne varijable po jedinicama promatranja i vremenu, sa sredinom 0 i varijancom σ_ε^2. Također, pretpostavlja se da su svi x_{itK} nezavisni s ε_{it} za sve i, t, K.

Kod panel modela s fiksnim učinkom konstantni član se mijenja sa svakom jedinicom promatranja, ali je konstantan u vremenu. Kad broj vremenskih perioda teži u beskonačnost ($t \rightarrow \infty$) procjenitelj fiksnog efekata za svaku jedinicu promatranja postaje konzistentan. Metoda procjene s fiksnim učinkom kontrolira nepromjenjive varijable (engl. time-invariant) čime dodatno smanjuje problem endogenosti koji proizlazi iz izostavljenih (engl. omitted) varijabli. Najčešće se radi o socijalnim, kulturnim i političkim poveznicama zemalja, institucionalnim sličnostima i sl., koje su izostavljene zbog svoje teže mjerljivosti ili nedostupnosti podataka. Kalemli-Ozcan, Papaioannou i Peydro (2013) ističu da upravo navedene varijable imaju značajan utjecaj na usklađivanje poslovnih ciklusa zemalja što opravdava upotrebu statičkog panela s fiksnim učinkom.

Osim već prikazane deskriptivne statistike i korelacijske matrice, prije panel analize napravljeno je još nekoliko testova: Studentov t-test jednakosti aritmetičkih sredina zavisne varijable između dva podrazdoblja kojim se utvrđuje postoji li potreba podjele uzorka na dva dijela [razdoblje prije krize (2001-2008) te krizno i postkrizno razdoblje (2009-2016)]; Hausmanov test da bi se utvrdio prikladni učinak (fiksni ili slučajni); Wooldridgeov test autokorelacije reziduala kojim se utvrđuje postoji li problem autokorelacije reziduala; te modificirani Waldov test da bi se utvrdilo postoji li problem heteroskedastičnosti reziduala.

Panel 1.

Panelom 1. analizira se izravni utjecaj financijske integracije na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone. Rezultati Studentovog t-testa zavisne varijable (BCS) prikazani u tablici 5. potvrđuju da ne postoji razlika aritmetičkih sredina između razdoblja prije krize (2001. – 2008.) i kriznog te postkriznog razdoblja (2009. – 2016.). Stoga uzorak nije potrebno dijeliti na dva dijela, već se ekonometrijska panel analiza panela može provesti na cijelom uzorku.

Tablica 5. Studentov t-test jednakosti artimetičkih sredina zavisne varijable (BCS)

Two-sample t test with equal variances

Variable	Obs	Mean	Std. Err.	Std. Dev.	[95% Conf.	Interval]
BCS40108	152	.6726151	.0418851	.5163941	.5898586	.7553716
BCS40916	152	.681072	.0401155	.4945776	.6018118	.7603322
combined	304	.6768436	.0289515	.5047862	.6198721	.733815
diff		-.0084569	.0579967		-.1225857	.1056719

```
    diff = mean(BCS40108) - mean(BCS40916)                        t =  -0.1458
Ho: diff = 0                                     degrees of freedom =      302

    Ha: diff < 0                 Ha: diff != 0                 Ha: diff > 0
 Pr(T < t) = 0.4421         Pr(|T| > |t|) = 0.8842          Pr(T > t) = 0.5579
```

Izvor: Izrada autora (Stata 14.2)

Izbor učinka statičkog panela određen je Hausmanovim testom. Rezultati Hausmanovog testa (prikazani u tablici 6.) potvrđuju prikladnost statičkog panela s fiksnim učinkom**.** Procjenu parametara modela putem statičkog panela s fiksnim učinkom u svom istraživanju također koriste Hsu, Wu i Yau (2011).

Tablica 6. Hausmanov test

	Coefficients (b) fe	(B) re	(b-B) Difference	sqrt(diag(V_b-V_B)) S.E.
logFI1	-.1608813	-.0703843	-.090497	.081475
logTI1	.2782544	.1610884	.117166	.1182204
logSS2	-1.693241	-.82576	-.8674813	.573714
logKFP	.0964029	.075978	.0204249	.0204943

```
                b = consistent under Ho and Ha; obtained from xtreg
 B = inconsistent under Ha, efficient under Ho; obtained from xtreg

    Test:  Ho:  difference in coefficients not systematic

                  chi2(4) = (b-B)'[(V_b-V_B)^(-1)](b-B)
                          =       11.15
                Prob>chi2 =      0.0250
```

Izvor: Izrada autora (Stata 14.2)

Wooldridgeov test autokorelacije reziduala (prikazan u tablici 7.) potvrđuje da postoji problem autokorelacije reziduala koji je uklonjen korištenjem zavisne varijable BCS s pomakom (lagirane zavisne varijable). Modificirani Waldov test (također prikazan u tablici 7.) potvrđuje da postoji heteroskedastičnost reziduala, a navedeni problem uklonjen je korištenjem Eicker-Huber-Whiteovog procjenitelja.

Tablica 7. Rezultati Wooldridgeovog testa i modificiranog Waldovog testa

```
Wooldridge test for autocorrelation in panel data
H0: no first-order autocorrelation
    F(  1,       18) =      6.897
           Prob > F =      0.0171

Modified Wald test for groupwise heteroskedasticity
in fixed effect regression model

H0: sigma(i)^2 = sigma^2 for all i

chi2 (19)  =    8843.30
Prob>chi2 =      0.0000
```

Izvor: Izrada autora (Stata 14.2)

U tablici 8. prikazani su rezultati procjene parametara modela statičkim panelom s fiksnim učinkom (panel 1a.). Ukupno je prikazano 13 modela, pri čemu modeli od (6) do (13) za nezavisnu varijablu imaju uključenu zavisnu varijablu s pomakom (lagirana BCS). Za razliku od njih, modeli od (1) do (5) nemaju uključenu zavisnu varijablu s pomakom. Iz tablice je vidljivo da rezultati (veličina i predznak koeficijenata nezavisnih varijabli) modela (1) do (5) ne pokazuju značajnija odstupanja od rezultata modela (6) do (13).

Tablica 8. Rezultati panela 1a.

	(1)	(2)	(3)	(4)	(5)	(6)	(7)
Usklađenost poslovnih ciklusa (BCS)							
Trgovinska integracija (TI1)	0.280 (0.105)**		0.242 (0.082)***	0.278 (0.108)**	0.277 (0.108)**		0.181 (0.058)**
Trgovinska integracija (TI2)		0.185 (0.096)*					
Financijska integracija (FI1)	-0.221 (0.105)**	-0.200 (0.099)*		-0.161 (0.093)*	-0.193 (0.099)*	-0.186 (0.653)**	
Financijska integracija (FI3)			-0.188 (0.076)**				
Sličnost sektorskih struktura (SS1)	-0.773 (0.683)	-0.818 (0.680)	-0.751 (0.686)			-0.517 (0.686)	-0.620 (0.611)
Sličnost sektorskih struktura (SS2)				-1.693 (0.784)**			
Sličnost sektorskih struktura (SS5)					-1.275 (0.884)		
Konvergencija fiskalnih politika (KFP)	0.088 (0.044)*	0.090 (0.043)**	0.064 (0.035)*	0.096 (0.047)*	0.099 (0.048)**	0.101 (0.044)**	0.037 (0.035)
lagirana BCS						0.170 (0.075)**	0.177 (0.066)**
constant	1.897 (0.999)*	2.263 (1.223)*	2.556 (0.891)***	0.128 (0.408)	0.179 (0.530)	0.692 (1.028)	2.033 (0.824)**

	(8)	(9)	(10)	(11)	(12)	(13)
Usklađenost poslovnih ciklusa (BCS)						
Trgovinska integracija (TI1)	0.264 (0.106)**	0.252 (0.101)**		0.212 (0.077)***	0.250 (0.102)**	0.248 (0.101)**
Trgovinska integracija (TI2)			0.175 (0.086)*			
Financijska integracija (FI1)	-0.249 (0.093)**	-0.226 (0.085)**	-0.208 (0.078)*		-0.175 (0.077)**	-0.200 (0.080)**
Financijska integracija (FI3)				-0.178 (0.069)**		
Sličnost sektorskih struktura (SS1)		-0.429 (0.657)	-0.456 (0.650)	-0.552 (0.625)		
Sličnost sektorskih struktura (SS2)					-1.252 (0.767)	
Sličnost sektorskih struktura (SS5)						-0.892 (0.825)
Konvergencija fiskalnih politika (KFP)	0.098 (0.043)**	0.103 (0.048)**	0.105 (0.047)**	0.077 (0.037)**	0.109 (0.050)**	0.111 (0.052)**
lagirana BCS	0.174 (0.076)**	0.163 (0.077)**	0.169 (0.077)**	0.153 (0.065)**	0.149 (0.077)**	0.161 (0.076)**
constant	0.573 (0.231)**	1.217 (0.968)	1.568 (1.134)	2.084 (0.802)**	0.134 (0.350)	0.181 (0.453)

Robusne standardne greške prikazane su u zagradama

***, **, * označava statističku značajnost na razini 1%, 5% i 10%

Izvor: Izrada autora

U svim testiranim modelima trgovinska integracija (TI1) pozitivno utječe na usklađivanje poslovnih ciklusa (BCS). Utjecaj je u svim modelima statistički značajan na razini 5%, osim u

modelima (3) i (11) u kojima je statistički značajan na razini 1%. Dodatno, veličina koeficijenta trgovinske integracije u modelima varira od 0,181 do 0,28, što znači da postoji ekonomska značajnost navedenog utjecaja. Rezultati panela su vrlo slični kad se za trgovinsku integraciju koristi TI2 - pozitivan, statistički značajan utjecaj na razini 10%, pri čemu veličina koeficijenta varira od 0,175 do 0,185.

Pozitivan, statistički značajan koeficijent α_2 potvrđuje da trgovinska integracija potiče usklađivanje poslovnog ciklusa Hrvatske sa poslovnim ciklusima zemalja eurozone generiranjem učinaka na strani potražnje. Ovo ukazuje na važnost trgovinskih tijekova kao kanala transmisije poslovih ciklusa iz zemalja eurozone u Hrvatsku. Pozitivan utjecaj trgovinske integracije na usklađivanje poslovnih ciklusa potvrđen je u brojnim sličnim istraživanjima: Frankel i Rose (1998), Kose, Prasad i Terones (2003), Imbs (2004), Traistaru (2004), Baxter i Kouparitsas (2005), Abbott, Easaw i Xing (2008), Siedschlag i Tondl (2011), Gouveia i Correia (2013), Antonakakis i Tondl (2014), Alimi (2015), Asteriou i Moudatsou (2015) te Duran i Ferreira Lopes (2017).

Predznak koeficijenta α_3 ovisi o izabranom indikatoru financijske integracije, čime se potvrđuje da različiti oblici kapitala putem različitih kanala utječu na usklađivanje poslovnih ciklusa. Financijska integracija (FI1) ima negativan predznak u svim testiranim modelima, što znači da financijska integracija negativno utječe na usklađivanje poslovnog ciklusa (uzrokuje divergenciju) Hrvatske s poslovnim ciklusima zemalja eurozone. Negativan, statistički značajan koeficijent α_3 (u slučaju korišenja FI1) potvrđuje da integracija tržišta kapitala putem kanala blagostanja potiče divergenciju poslovnog ciklusa Hrvatske i poslovnih ciklusa zemalja eurozone. Djelovanje kanala blagostanja u skladu je s teorijom realnih poslovnih ciklusa (Backus, Kehoe i Kydland, 1992) prema kojoj visoko mobilni kapital pojačava djelovanje šokova ukupne faktorske produktivnosti i na taj način uzrokuje divergenciju poslovnih ciklusa zemalja. U skladu s time, ovakav rezultat u panelu može se objasniti činjenicom da izravne strane investicije sele u područja s većim stopama rasta, tj. kapitalni tokovi veći su između zemalja koje imaju različite stope rasta. Hrvatska (koja je neto primateljica izravnih stranih investicija) najveći priljev izravnih stranih investicija prije krize ostvaruje iz zemalja jezgre eurozone (Njemačka, Francuska, Austrija) koje u tom razdoblju

ostvaruju niže stope rasta od Hrvatske[29]. S navedenim zemljama Hrvatska ima manju usklađenost poslovnih ciklusa nego s rubnim zemljama eurozone (osim Grčke i baltičkih zemalja).

Dodatno, u modelima od (6) do (13) (osim modela (10)) financijska integracija statistički je značajna na razini 5%, dok je u modelima od (1) do (5) (osim modela (1)) statistički značajna na razini 10%. Na temelju veličine koeficijenta, koji varira od -0,161 do -0,249, može se zaključiti da postoji ekonomska značajnost utjecaja.

Negativan utjecaj financijske integracije na usklađivanje poslovnih ciklusa zemalja u svojim radovima potvrđuju: Xing i Abbott (2007), Garcia-Herrero i Ruiz (2008), Cerqueira i Martins (2009), Lee i Azali (2010), Pontines i Parulian (2010) te Antonakakis i Tondl (2014).

Kad se za indikator financijske integracije koristi realna stopa povrata na desetogodišnje obveznice (FI3), predznak koeficijenta u modelu se mijenja. Naime, u oba testirana modela FI3 ima negativan predznak što znači da (zbog načina mjerenja FI3) integracija tržišta kredita putem kanala bilance potiče usklađivanje poslovnog ciklusa Hrvatske sa zemalja eurozone. Djelovanje kanala bilance u skladu je s Krugmanovim međunarodnim financijskim multiplikatorom (Krugman, 2008) koji putem kontrakcije/ekspanzije bilanci banaka potiče usklađivanje poslovnih ciklusa zemalja.

Financijska integracija (FI3) statistički je značajna na razini 5% u oba testirana modela (model (3) i model (11)), a na temelju veličine koeficijenta, koji varira od -0,178 do -0,188, može se zaključiti da postoji ekonomska značajnost utjecaja.

Pozitivan utjecaj financijske integracije na usklađivanje poslovnih ciklusa zemalja u svojim radovima potvrđuju: Kose, Prasad i Terones (2003), Imbs (2004), Jansen i Stokman (2004), Schiavo (2008), Dees i Zorel (2012) te Davis (2014).

Sličnost sektorskih struktura (SS1) ima negativan predznak što implicira da (zbog načina mjerenja) Hrvatska veću usklađenost poslovnih ciklusa ostvaruje sa zemljama eurozone s kojima ima sličniju sektorsku strukturu. Iako je koeficijent α_4 poprilično velik (varira od -0,429 do -

[29] Amplitudna usklađenost poslovnih ciklusa prikazana je u prilogu 1. Priljev FDI iz zemalja eurozone u Hrvatsku pogledati u poglavlju 5.2.2.

0,818) i teorijski očekivanog predznaka, njegov utjecaj nije statistički značajan na razini 10% ni u jednom od testiranih modela.

Rezultati se ne mijenjaju s promjenom razine agregacije sektorske aktivnosti (logSS2) niti s promjenom načina mjerenja (SS5) što potvrđuje robusnost rezultata. Ovakav rezultat može se objasniti snažnijim utjecajem zajedničkih šokova (kod kojih je manje važna sektorska struktura, nego kod sektorski specifičnih šokova) te uspješnim djelovanjem mehanizama za apsorpciju šokova u dijelu promatranog razdoblja.

Za razliku od istraživanja Imbsa (2004), Siedschlag (2010) te Siedschlag i Tondl (2011), koji potvrđuju negativan utjecaj divergencije sektorskih struktura na usklađivanje poslovnih ciklusa zemalja, rezultati ovog panela u skladu su s istraživanjem Baxtera i Kouparitsasa (2005) te Clarka i Wincoopa (2001) koji ne pronalaze statistički značajan utjecaj.

U svim testiranim modelima konvergencija fiskalnih politika (KFP) pozitivno utječe na usklađivanje poslovnih ciklusa (BCS), pri čemu je utjecaj statistički značajan na razini 5% [u svim modelima osim modela (1), (3) i (7)]. Na temelju veličine koeficijenta (koji varira od 0,037 do 0,111) može se zaključiti da postoji ekonomska značajnost utjecaja.

Pozitivan, statistički značajan koeficijent α_1 potvrđuje da konvergencija fiskalnih politika pozitivno utječe na usklađivanje poslovnog ciklusa Hrvatske s poslovnim ciklusima zemalja eurozone. Dakle, divergentne fiskalne politike potaknile su stvaranje idiosinkratskih šokova čime su smanjile usklađenost poslovnog ciklusa Hrvatske sa zemljama eurozone. Na taj način povećani su troškovi monetarnog integriranja Hrvatske. Očigledno su fiskalne politike procikličkog karaktera što može biti problematično jer anticikličke fiskalne politike u eurozoni predstavljaju važan mehanizam apsorpcije asimetričnih šokova potražnje. Rezultati panela u skladu su s istraživanjima Bowera i Gullemineaua (2006), Darvasa, Rosea i Szaparya (2007), Artisa, Fidrmuca i Scharlera (2008), Inklaara, Jong-A-Pina i De Haana (2008), Fonsece, Patureaua i Sopraseutha (2010), Alimija (2015), Antonakakisa i Tondla (2014) te Lukmanove i Tondla (2017).

S obzirom na to da u panelu 1a. postoji autokorelacija i heteroskedastičnost reziduala, robusnost rezultata testirana je korištenjem PCSE procjenitelja (engl. panel corrected standard errors) koji je

postojan kod problema autokorelacije i heteroskedastičnosti reziduala. Hoechle (2007) ističe da PCSE procjenitelj nije prikladan za korištenje na uzorcima u kojima je vremenska dimenzija veća od prostorne (T>N). U skladu s time sužen je vremenski interval - u panelu 1b. obuhvaća razdoblje od 2009. do 2016. godine. Rezultati panela 1b. prikazani su u tablici 9.

Tablica 9. Rezultati panela 1b. (2009.-2016.)

	(1)	(2)	(3)	(4)	(5)	(6)	(7)
Usklađenost poslovnih ciklusa (BCS)							
Trgovinska integracija (TI1)	0.294 (0.101)***	0.149 (0.074)**	0.252 (0.100)***	0.121 (0.075)*	0.212 (0.087)**	0.223 (0.091)***	
Trgovinska integracija (TI2)							0.257 (0.105)***
Financijska integracija (FI1)	-0.115 (0.043)***		-0.086 (0.034)***		-0.078 (0.036)**	-0.083 (0.037)**	-0.091 (0.045)**
Financijska integracija (FI3)		-0.228 (0.117)**		-0.211 (0.114)*			
Sličnost sektorskih struktura (SS1)			-0.350 (0.282)	-0.457 (0.358)			
Sličnost sektorskih struktura (SS2)					-0.772 (0.407)*		
Sličnost sektorskih struktura (SS5)						-0.700 (0.450)	
Konvergencija fiskalnih politika (KFP)							
Constant	1.164 (0.229)***	1.212 (0.259)***	1.618 (0.362)***	1.766 (0.389)***	0.637 (0.343)*	0.659 (0.389)*	1.860 (0.479)***

	(8)	(9)	(10)	(11)	(12)	(13)	(14)
Usklađenost poslovnih ciklusa (BCS)							
Trgovinska integracija (TI1)	0.095 (0.073)	0.171 (0.093)*	0.140 (0.084)*	0.144 (0.086)*			
Trgovinska integracija (TI2)					0.168 (0.088)**	0.122 (0.083)	0.127 (0.085)
Financijska integracija (FI1)		-0.075 (0.027)***	-0.074 (0.028)***	-0.078 (0.029)***	-0.066 (0.025)***	-0.063 (0.028)**	-0.066 (0.028)**
Financijska integracija (FI3)	-0.206 (0.110)*						
Sličnost sektorskih struktura (SS1)	-0.382 (0.345)	-0.478 (0.256)*			-0.509 (0.241)**		
Sličnost sektorskih struktura (SS2)			-0.861 (0.396)**			-0.873 (0.394)**	
Sličnost sektorskih struktura (SS5)				-0.847 (0.422)**			-0.860 (0.419)**
Konvergencija fiskalnih politika (KFP)	0.151 (0.076)**	0.240 (0.088)***	0.237 (0.089)***	0.239 (0.089)***	0.248 (0.088)***	0.244 (0.089)***	0.247 (0.090)***
Constant	1.586 (0.413)***	1.607 (0.316)***	0.400 (0.340)	0.372 (0.373)	2.148 (0.498)***	0.725 (0.511)	0.709 (0.545)

Robusne standardne greške prikazane su u zagradama

***, **, * označava statističku značajnost na razini 1%, 5% i 10%

Izvor: Izrada autora

Rezultati panela 1b. većinom potvrđuju rezultate panela 1a. Iz tablice je vidljivo da trgovinska integracija potiče usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone. Pad trgovinske integracije (trgovine) za vrijeme i nakon krize potaknuo je divergenciju poslovnih ciklusa navedenih zemalja. Utjecaj financijske integracije na usklađivanje poslovnog ciklusa Hrvatske sa

zemljama eurozone ovisi o izboru indikatora. Naime, FI1 negativno, statistički značajno utječe na usklađivanje poslovnih ciklusa promatranih zemalja, a FI3 pozitivno (negativan predznak u panelu je zbog načina mjerenja), statistički značajno utječe na usklađivanje poslovnih ciklusa promatranih zemalja. Konvergencija fiskalnih politika potiče usklađivanje poslovnog ciklusa Hrvatske s poslovnim ciklusima zemalja eurozone, pri čemu je statistička značajnost veća nego u panelu 1a [u svim testiranim modelima, osim u modelu (1), utjecaj je statistički značajan na razini 1%]. Dodatno, u panelu 1b. koeficijent varira od 0,151 do 0,249 (veća vrijednost nego u panelu 1a.) što ukazuje na važnost konvergencije fiskalnih politika promatranih zemalja u kriznom i postkriznom razdoblju. Konačno, sličnost sektorskih struktura ima negativan predznak, što znači da Hrvatska ima usklađenije poslovne cikluse sa zemalja eurozone s kojima ima sličniju sektorsku strukturu. Za razliku od panela 1a., u promatranom panelu utjecaj je statistički značajan na razini 5% (u modelima (10) i (13) te (11) i (14)) u kojima se sektorska struktura promatra na nižoj razini agregacije (SS2 i SS5)). Veličina koeficijenta u modelima varira od -0,861 do -0,873 za logSS2, a kod logSS5 od -0,847 do -0,860 što ukazuje na ekonomsku značajnost utjecaja. Razlika u statističkoj značajnosti rezultata između panela 1b. i panela 1a. proizlazi iz suženog vremenskog razdoblja panela 1b. Naime, u razdoblju od 2009. do 2016. godine dolazi do pucanja kreditnog kanala i posljedično pojačanog utjecaja šokova s asimetričnom transmisijom. U takvoj situaciji dolazi do izražaja važnost sličnih sektorskih struktura za simetričnu transmisiju šokova.

Na temelju prikazanih rezultata panela 1a. i 1b. prihvaća se hipoteza H1 koja pretpostavlja da financijska integracija izravno pozitivno utječe na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone.

Međutim, navedeni utjecaj potrebno je objasniti u kontekstu problema ove disertacije. Kao što je već ranije naglašeno, važnost financijske integracije za funkcioniranje valutnog područja, kao i za zemlje koje će pristupiti valutnom području (među koje spada Hrvatska), proizlazi iz mehanizama apsorpcije idiosinkratskih šokova. Naime, monetarnim integriranjem zemlje se odriču vlastite monetarne politike i time gube mogućnost anticikličkog djelovanja na idiosinkratske šokove (šokove specifične za zemlju). Stoga je potrebno naglasiti važnost i objasniti djelovanje tržišnog mehanizma podjele rizika koji je omogućen financijskom integracijom.

Dva osnovna kanala koja djeluju u sklopu tržišnog mehanizma podjele rizika su kapitalni kanal i kreditni kanal (Cimadomo i ostali, 2018). Kapitalni kanal funkcionira putem ukriženog prava vlasništva na proizvodnu imovinu, dakle primarno je vezan uz izravne strane investicije i portfeljne investicije. Dakle, utjecaj FI1 (indikator – izravne strane investicije) na usklađivanje poslovnih ciklusa djeluje putem kapitalnog kanala. Iako je očekivani teorijski predznak navedenog utjecaja pozitivan, iz panela 1a. i 1b. vidljivo je da je utjecaj FI1 na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone negativan.

Predznak utjecaja proizlazi iz načina mjerenja FI1. Naime, FI1 ima snažno rastući trend prije pojave krize, u situaciji relativno usklađenog poslovnog ciklusa Hrvatske s poslovnim ciklusima zemalja eurozone. S pojavom krize dolazi do pada usklađenosti poslovnih ciklusa promatranih zemalja, dok istovremeno izravne strane investicije zadržavaju blago rastući trend (jer se radi o stanju dolaznih i odlaznih izravnih stranih investicija). Iz tog odnosa proizlazi negativan predznak, koji zapravo ne znači da izravne strane investicije uzrokuju divergenciju poslovnih ciklusa, već zahtijeva drugačije objašnjenje.

Objašnjenje utjecaja treba tražiti u snazi kapitalnog kanala, tj. sposobnosti da *ex ante* ugladi dohodak, i na taj način smanji rizik od pojave idiosinkratskih šokova između Hrvatske i zemalja eurozone. Na grafikonu 8. prikazani su podaci o stanju dolaznih izravnih stranih investicija u Hrvatsku iz zemalja eurozone (u milijunima eura), a na grafikonu 9. podaci o stanju odlaznih izravnih stranih investicija iz Hrvatske u zemlje eurozone (također u milijunima eura). Očigledno je da Hrvatska ima relativno mali udio stanja izravnih stranih investicija u BDP-u (pogotovo odlaznih izravnih stranih investicija), što implicira da kapitalni kanal nije dovoljno snažan za značajnije osiguranje (uglađivanje) dohotka, tj. apsorpciju asimetričnih šokova između Hrvatske i zemalja eurozone. To posebno dolazi do izražaja iza 2008. godine kada dolazi do divergencije poslovnog ciklusa Hrvatske i poslovnih ciklusa zemalja eurozone. Navedeno je u skladu s Milanom i Reischlinom (2017) koji ističu da je u eurozoni podjela rizika putem kapitalnog kanala značajno manja nego putem kreditnog kanala[30].

[30] Milano i Reischlin (2017) ga zovu kanal štednje, a obuhvaća interno i eksterno pozajmljivanje i zaduživanje od strane privatnog i javnog sektora.

S druge strane, kreditni kanal je dominantni kanal tržišnog mehanizma za uglađivanje idiosinkratskih šokova u eurozoni. Predstavlja *ex post* aranžman (nakon pojave šokova) koji se temelji na zaduživanju privatnog i javnog sektora na kreditnim tržištima. Iz toga proizlazi da FI3 (indikator - stopa povrata na desetogodišnje obveznice) utječe na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone putem kreditnog kanala. Rezultati panela u skladu su s teorijskim predznakom - pozitivni utjecaj FI3 na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone, što je posljedica apsorpcije idiosinkratskih šokova (koja u konačnici rezultira usklađivanjem poslovnih ciklusa).

Međutim, važno je istaknuti da utjecaj kreditnog kanala može biti vrlo problematičan kod pojave krize. Furceri i Zdzienicka (2015) potvrđuju da je udio neapsorbiranih šokova u kriznim vremenima značajno veći nego u normalnim vremenima. Iz grafikona 10. vidljivo je da je do pojave krize postojala snažna integracija kreditnog tržišta (koja se očituje u maloj razlici povrata na desetogodišnje obveznice) koja je putem zaduživanja omogućavala apsorpciju idiosinkratskih šokova. S pojavom krize došlo je do dezintegracije kreditnog tržišta zbog pojave averzije prema riziku i reevaluacije kreditnog rizika. U takvoj situaciji dolazi do pucanja kreditnog kanala – što onemogućava da se putem zaduživanja apsorbiraju idiosinkratski šokovi i na taj način usklade poslovni ciklusi (Hrvatske s poslovnim ciklusima zemalja eurozone). Iz navedenog proizlazi pozitivan utjecaj financijske integracije (FI3) na usklađivanje poslovnih ciklusa (BCS) u panelima 1a. i 1b.

Grafikon 8. Stanje dolaznih izravnih stranih investicija iz zemalja eurozone u Hrvatsku

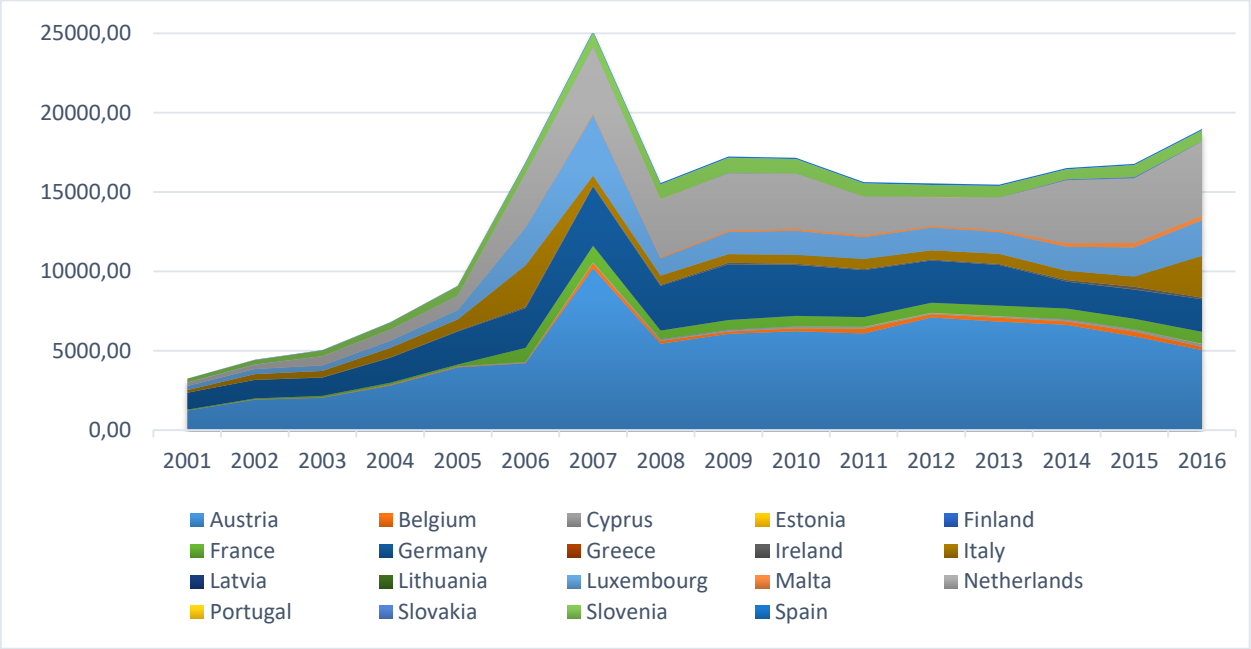

Izvor: Izrada autora

Grafikon 9. Stanje odlaznih izravnih stranih investicija iz Hrvatske u zemlje eurozone

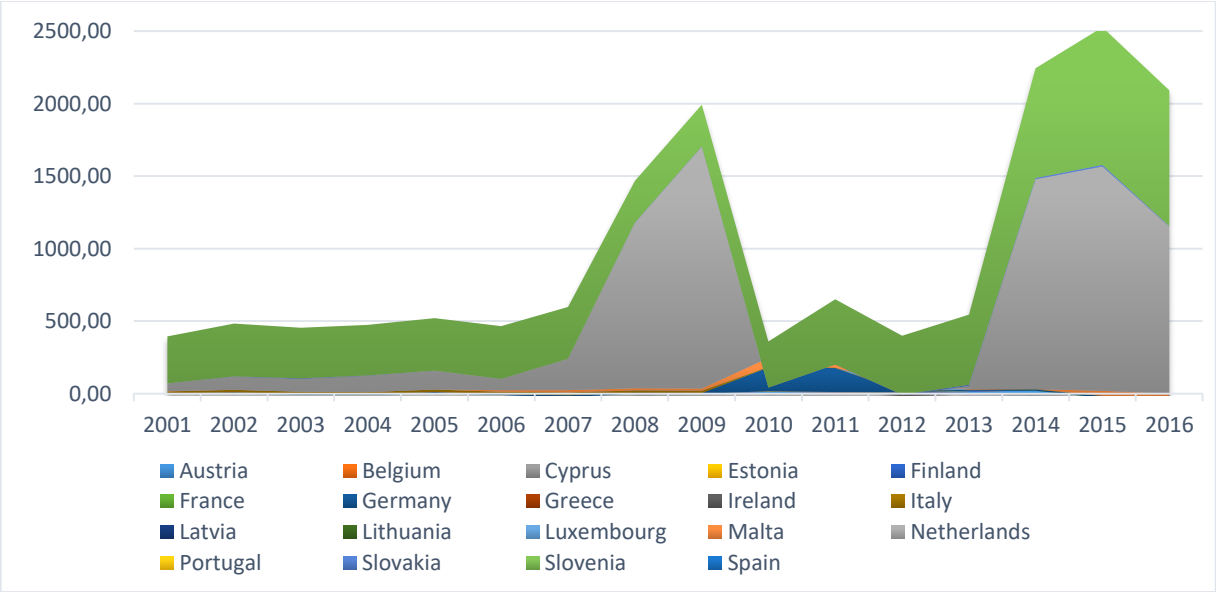

Izvor: Izrada autora

Grafikon 10. Realna stopa povrata na desetogodišnje obveznice

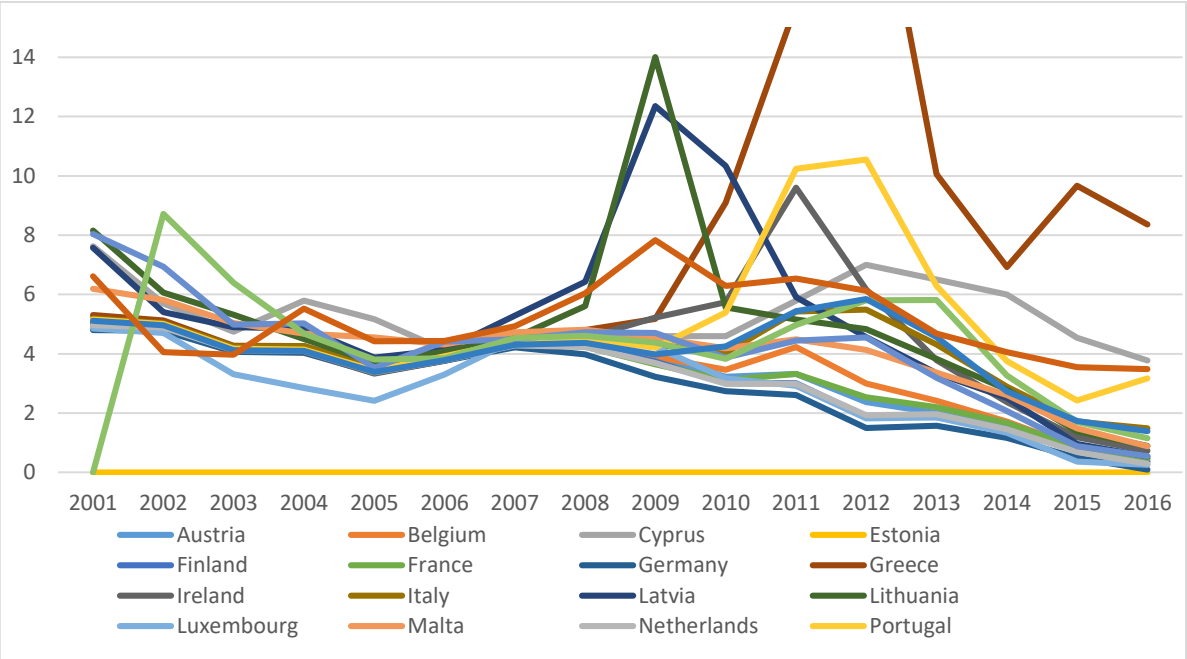

Izvor: Izrada autora

Panel 2.

Panelom 2. analizira se utjecaj financijske integracije na sektorsku strukturu Hrvatske i zemalja eurozone (tj. sličnost njihovih sektorskih struktura). Isto kao i kod panela 1., prvi korak u ekonometrijskoj analizi panela 2. predstavlja analiza jednakosti aritmetičkih sredina zavisne varijable putem Studentovog t-testa. U tablici 10. prikazani su rezultati Studentovog t-testa zavisne varijable (logSS2) koji potvrđuju da postoji razlika aritmetičkih sredina između razdoblja prije krize (2001.-2008.) i kriznog te postkriznog razdoblja (2009.-2016.). Stoga je kod ekonometrijske panel analize vremensko razdoblje podijeljeno na dva podrazdoblja te je za svako od podrazdoblja provedena zasebna panel analiza.

Tablica 10. Rezultati t-testa zavisne varijable (logSS2) panela 2.

```
Two-sample t test with equal variances
------------------------------------------------------------------------------
Variable |     Obs        Mean    Std. Err.   Std. Dev.   [95% Conf. Interval]
---------+--------------------------------------------------------------------
logSS2~8 |     152   -.5489766    .0085663    .1056119   -.5659018   -.5320514
logSS2~6 |     152   -.5131917     .009389    .1157556   -.5317425   -.4946409
---------+--------------------------------------------------------------------
combined |     304   -.5310841     .006427    .1120594   -.5437314   -.5184369
---------+--------------------------------------------------------------------
    diff |           -.0357849    .0127096               -.0607956   -.0107743
------------------------------------------------------------------------------
    diff = mean(logSS20108) - mean(logSS20916)                    t =  -2.8156
Ho: diff = 0                                     degrees of freedom =      302

    Ha: diff < 0                 Ha: diff != 0                 Ha: diff > 0
 Pr(T < t) = 0.0026         Pr(|T| > |t|) = 0.0052          Pr(T > t) = 0.9974
```

Izvor: Izrada autora (Stata 14.2)

Robusnost rezultata panela 2. testirana je korištenjem sektorske strukture na nižoj razini agregacije (logSS5). U skladu s time napravljen je Studentov t-test jednakosti aritmetičkih sredina između razdoblja prije krize (2001. – 2008.) i kriznog te postkriznog razdoblja (2009.-2016.) za varijablu logSS5. U tablici 11. prikazani su rezultati Studentovog t-testa.

Tablica 11. Rezultati t-testa zavisne varijable (logSS5) panela 2.

```
Two-sample t test with equal variances
------------------------------------------------------------------------------
Variable |     Obs        Mean    Std. Err.   Std. Dev.   [95% Conf. Interval]
---------+--------------------------------------------------------------------
lo~50108 |     152    -.598629    .0080958    .0998121   -.6146248   -.5826333
lo~50916 |     152   -.5609923    .0088673    .1093237   -.5785123   -.5434723
---------+--------------------------------------------------------------------
combined |     304   -.5798107    .0060904    .1061894   -.5917955   -.5678259
---------+--------------------------------------------------------------------
    diff |           -.0376367    .0120072                -.061265   -.0140085
------------------------------------------------------------------------------
    diff = mean(logSS50108) - mean(logSS50916)                    t =  -3.1345
Ho: diff = 0                                     degrees of freedom =      302

    Ha: diff < 0                 Ha: diff != 0                 Ha: diff > 0
 Pr(T < t) = 0.0009         Pr(|T| > |t|) = 0.0019          Pr(T > t) = 0.9991
```

Izvor: Izrada autora (Stata 14.2)

Rezultati Studentovog t- testa potvrđuju da postoji razlika aritmetičkih sredina sličnosti sektorskih struktura (logSS5) između razdoblja prije krize (2001. – 2008.) i kriznog te postkriznog razdoblja

(2009. – 2016.). Stoga je (isto kao i kod sličnosti sektorskih struktura (logSS2)) kod ekonometrijske analize vremensko razdoblje podijeljeno na dva podrazdoblja: razdoblje prije krize (2001. – 2008.) i krizno te postkrizno razdoblje (2009. – 2016.).

Na grafikonu 11. prikazani su dijagrami rasipanja za razdoblje od 2001. do 2008. godine. Iz dijagrama rasipanja vidljivo je da regresijski pravac međuodnosa financijske integracije (logFI1) i sličnosti sektorskih struktura ima pozitivan nagib, a navedeni pravac ne mijenja značajno nagib s promjenom indikatora i načina mjerenja sličnosti sektorskih struktura (logSS1, logSS2 i logSS5), tj. ne ovisi o tome na kojoj razini agregacije sektorskih struktura zemalja se promatra navedeni međuodnos. S obzirom na način mjerenja sličnosti sektorskih struktura, potvrđuje se snažna negativna linearna veza između financijske integracije i sličnosti sektorskih struktura, što indicira da financijska integracija potiče divergenciju sektorskih struktura Hrvatske od sektorskih struktura zemalja eurozone.

Dalje, vidljivo je da regresijski pravac međuodnosa trgovinske integracije (logTI1) i sličnosti sektorskih struktura (logSS2) ima negativan nagib, a navedeni pravac ne mijenja značajno nagib s promjenom načina mjerenja trgovinske integracije (korištenjem logTI2) te s promjenom načina mjerenja sličnosti sektorskih struktura (korištenjem logSS5). S obzirom na način mjerenja sličnosti sektorskih struktura, potvrđuje se snažna pozitivna linearna veza između trgovinske integracije i sličnosti sektorskih struktura, što indicira da trgovinska integracija potiče konvergenciju sektorskih struktura Hrvatske i zemalja eurozone. Međutim, s obzirom da odnos između trgovinske intregracije i sličnosti sektorskih struktura nije teorijski očekivanog predznaka, ovakav rezultat će se dodatno obrazložiti kod tumačenja rezultata panela 2.

Regresijski pravac međuodnosa stupnja razvijenosti zemalja (logGDPPC1) i sličnosti sektorskih struktura (logSS2) ima pozitivan nagib, a navedeni pravac ne mijenja značajno nagib s promjenom načina mjerenja stupnja razvijenosti zemalja (logGDPPC2). Potvrđuje se snažna pozitivna linearna veza između stupnja razvijenosti zemalja i sličnosti sektorskih struktura što indicira da stupanj razvijenosti utječe na kompoziciju sektorskih struktura promatranih zemalja.

Konačno, regresijski pravac međuodnosa veličine zemalja (logGDPprod) i sličnosti sektorskih struktura (logSS2) ima negativan nagib što (zbog načina mjerenja varijabli) potvrđuje da postoji

pozitivna linearna veza između veličine promatranih zemalja i sličnosti njihovih sektorskih struktura. Navedeno indicira da veće zemlje imaju diversificiranije (a time i sličnije) ekonomije, za razliku od manjih ekonomija koje su u pravilu specijaliziranije.

Grafikon 11. Dijagrami rasipanja (2001.-2008.)

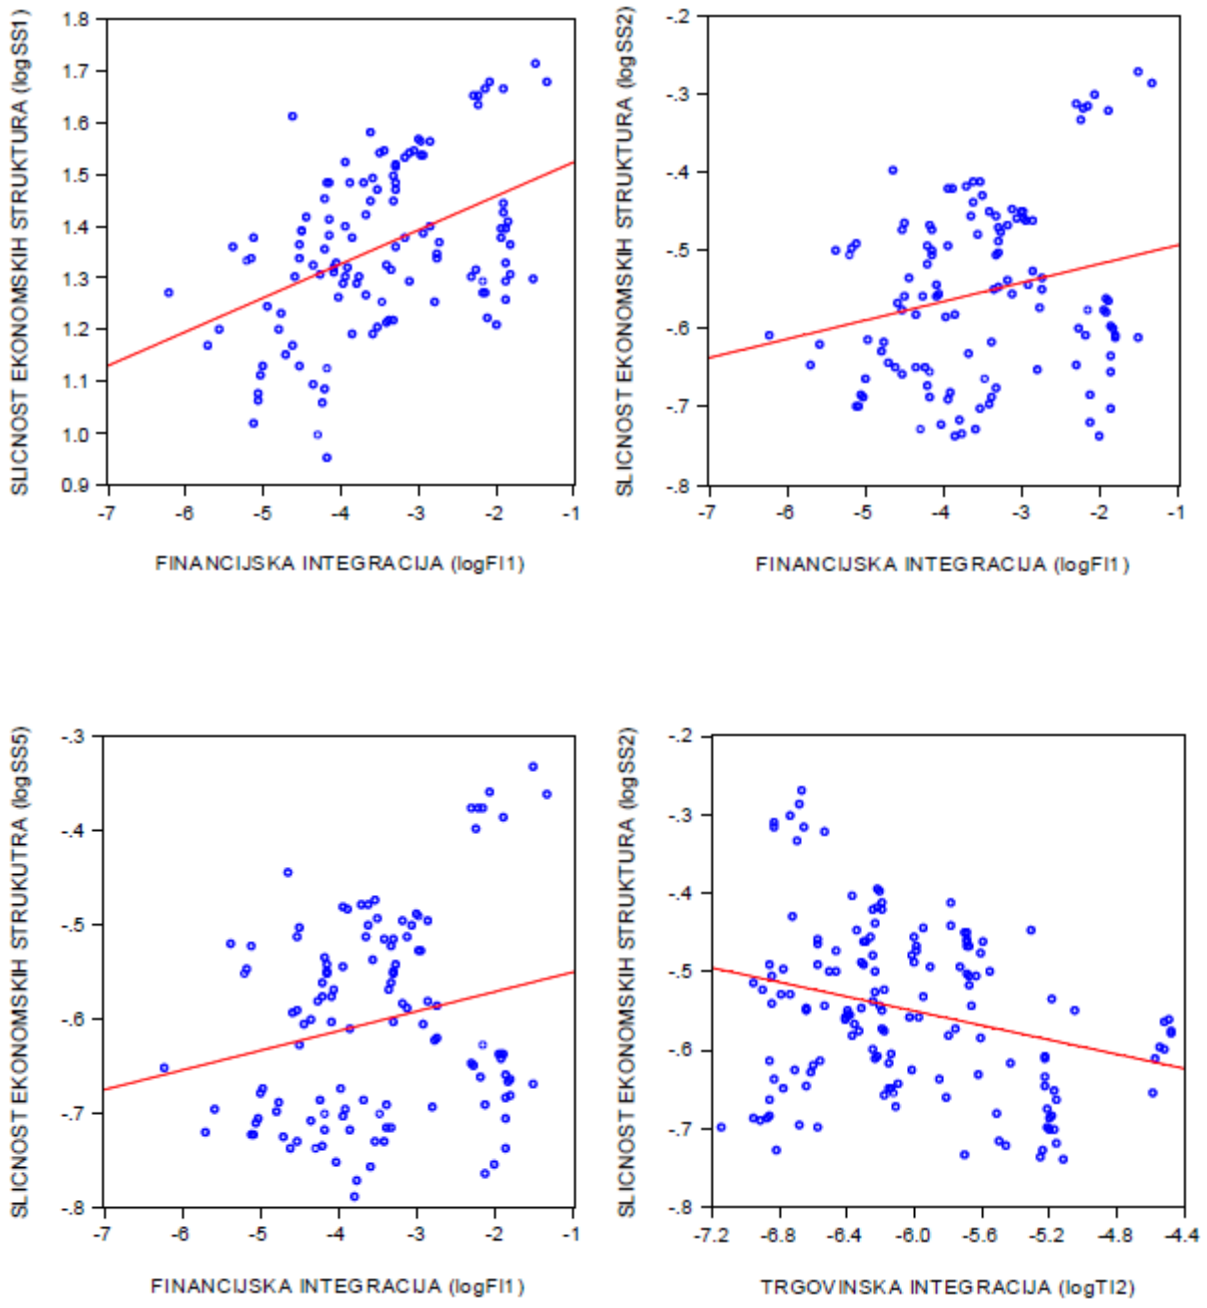

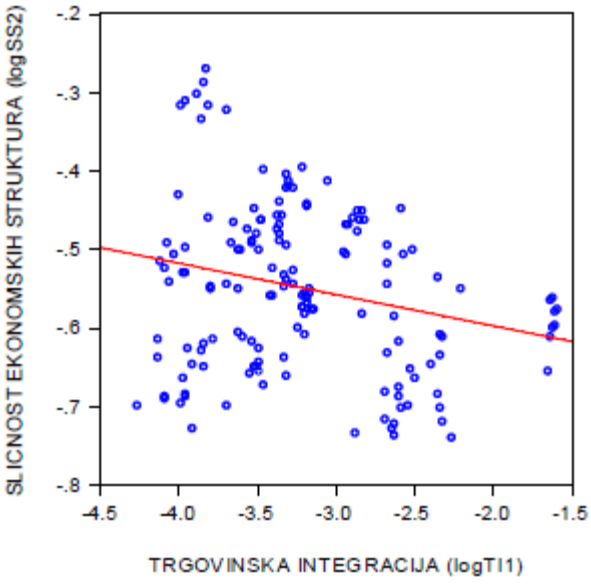
SLICNOST EKONOMSKIH STRUKTURA (logSS2)
-.2
-.3
-.4
-.5
-.6
-.7
-.8
-4.5
-4.0
-3.5
-3.0
-2.5
-2.0
-1.5
TRGOVINSKA INTEGRACIJA (logTI1)

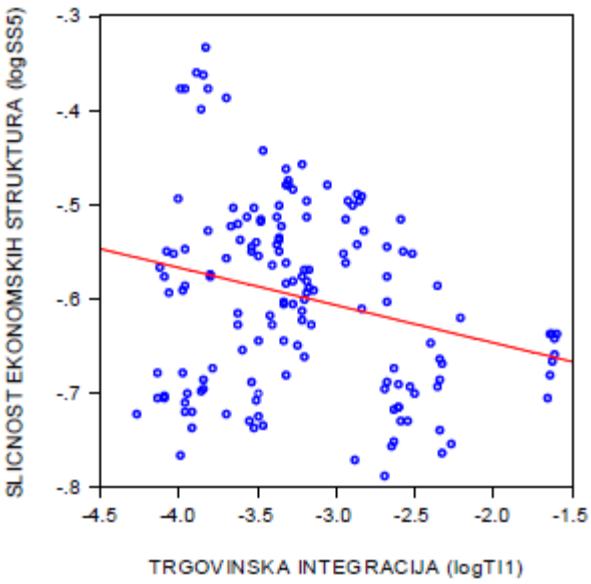
SLICNOST EKONOMSKIH STRUKTURA (logSS5)
-.3
-.4
-.5
-.6
-.7
-.8
-4.5
-4.0
-3.5
-3.0
-2.5
-2.0
-1.5
TRGOVINSKA INTEGRACIJA (logTI1)

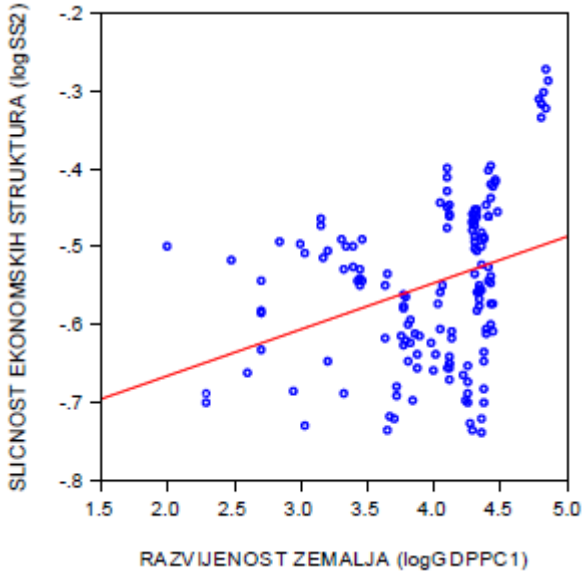
SLICNOST EKONOMSKIH STRUKTURA (logSS2)
-.2
-.3
-.4
-.5
-.6
-.7
-.8
1.5
2.0
2.5
3.0
3.5
4.0
4.5
5.0
RAZVIJENOST ZEMALJA (logGDPPC1)

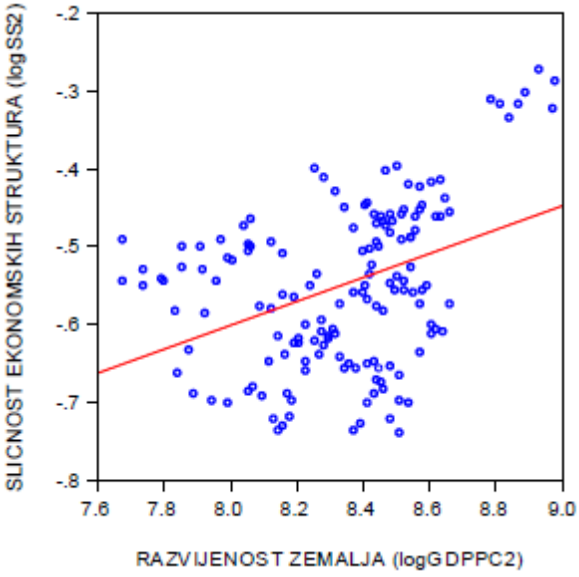
SLICNOST EKONOMSKIH STRUKTURA (logSS2)
-.2
-.3
-.4
-.5
-.6
-.7
-.8
7.6
7.8
8.0
8.2
8.4
8.6
8.8
9.0
RAZVIJENOST ZEMALJA (logGDPPC2)

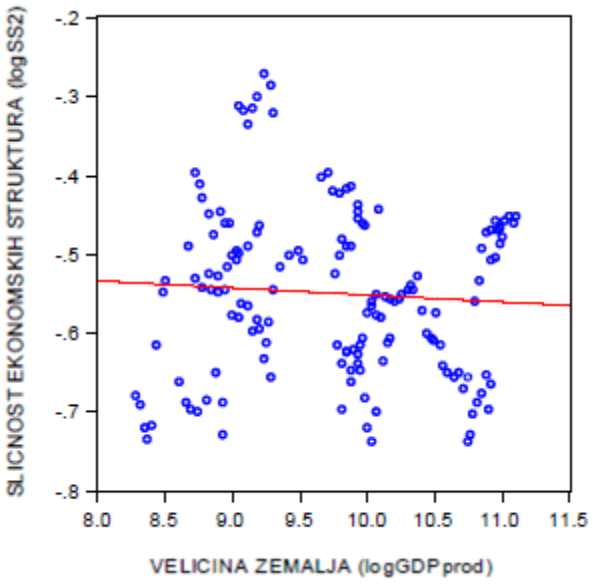

Izvor: Izrada autora (EViews 9)

Na grafikonu 12. prikazani su dijagrami rasipanja za krizno i postkrizno razdoblje (od 2009. do 2016. godine) iz kojih je vidljivo da regresijski pravac međuodnosa financijske integracije (logFI1) i sličnosti sektorskih struktura ima pozitivan nagib. Nagib navedenog pravca ovisi o načinu mjerenja sličnosti sektorskih struktura (logSS1, logSS2 i logSS5) tj. ovisi o tome na kojoj razini agregacije se promatraju sektorske strukture zemalja (nagib regresijskog pravca je veći kad se međuodnos promatra na višoj razini sektorske agregacije). S obzirom na način mjerenja sličnosti sektorskih struktura, potvrđuje se snažna negativna linearna veza između financijske integracije i sličnosti sektorskih struktura, što indicira da financijska integracija putem specijalizacije potiče divergenciju sektorske strukture Hrvatske od sektorskih struktura zemalja eurozone.

Dalje, slično kao i kod dijagrama rasipanja za razdoblje od 2001. do 2008. godine, regresijski pravac međuodnosa trgovinske integracije (logTI1) i sličnosti sektorskih struktura u kriznom i postkriznom razdoblju ima negativan nagib. Regresijski pravac ne mijenja značajno nagib s promjenom načina mjerenja trgovinske integracije (logTI2) i sličnosti sektorskih struktura (logSS1, logSS2 i logSS5).

Regresijski pravac međuodnosa stupnja razvijenosti zemalja (logGDPPC1) i sličnosti njihovih sektorskih struktura (logSS2) ima pozitivan nagib, a nagib pravca ne mijenja se s promjenom načina mjerenja razvijenosti (logGDPPC2). Potvrđuje se snažna pozitivna linearna veza između stupnja razvijenosti Hrvatske i zemalja eurozone i sličnosti njihovih sektorskih struktura, što indicira da sektorska struktura promatranih zemalja ovisi o stupnju njihove razvijenosti (što je veća razlika u stupnju razvijenosti između Hrvatske i zemalja eurozone, veća je razlika njihovih sektorskih struktura).

Konačno, regresijski pravac međuodnosa veličine zemalja (logGDPprod) i sličnosti sektorskih struktura (logSS2) ima negativan nagib čime se (zbog načina mjerenja varijabli) potvrđuje pozitivna linearna veza između veličine promatranih zemalja i sličnosti njihovih sektorskih struktura.

Grafikon 12. Dijagrami rasipanja (2009.-2016.)

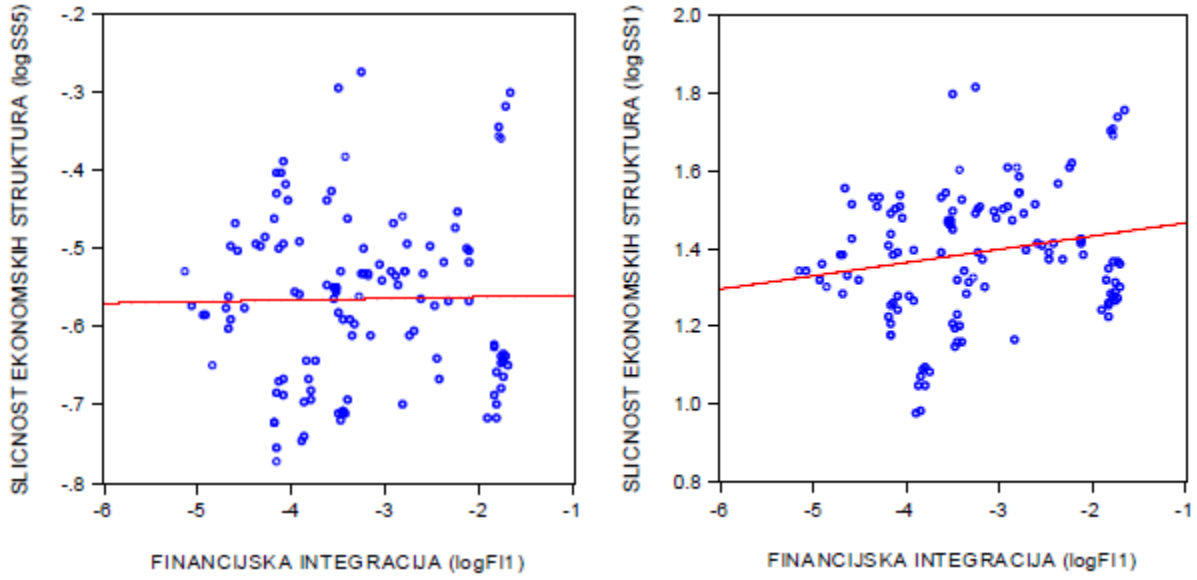

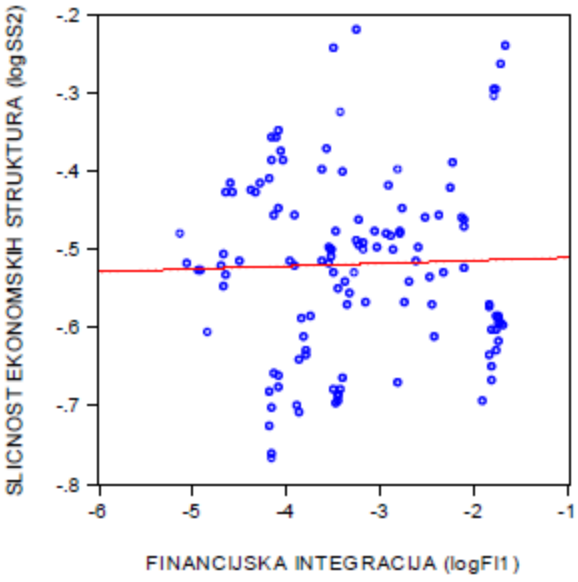
SLICNOST EKONOMSKIH STRUKTURA (logSS2)
-.2
-.3
-.4
-.5
-.6
-.7
-.8
-6
-5
-4
-3
-2
-1
FINANCIJSKA INTEGRACIJA (logFI1)

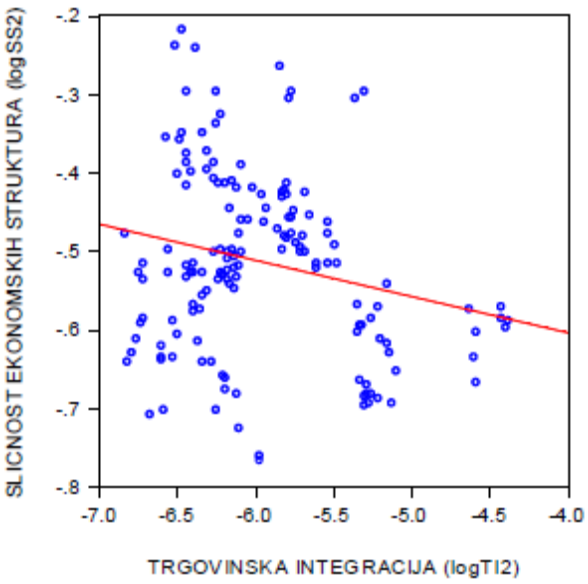
SLICNOST EKONOMSKIH STRUKTURA (logSS2)
-.2
-.3
-.4
-.5
-.6
-.7
-.8
-7.0
-6.5
-6.0
-5.5
-5.0
-4.5
-4.0
TRGOVINSKA INTEGRACIJA (logTI2)

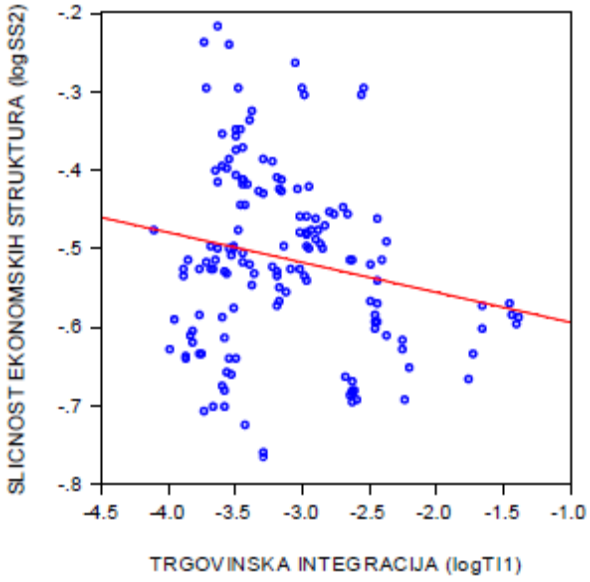
SLICNOST EKONOMSKIH STRUKTURA (logSS2)
-.2
-.3
-.4
-.5
-.6
-.7
-.8
-4.5
-4.0
-3.5
-3.0
-2.5
-2.0
-1.5
-1.0
TRGOVINSKA INTEGRACIJA (logTI1)

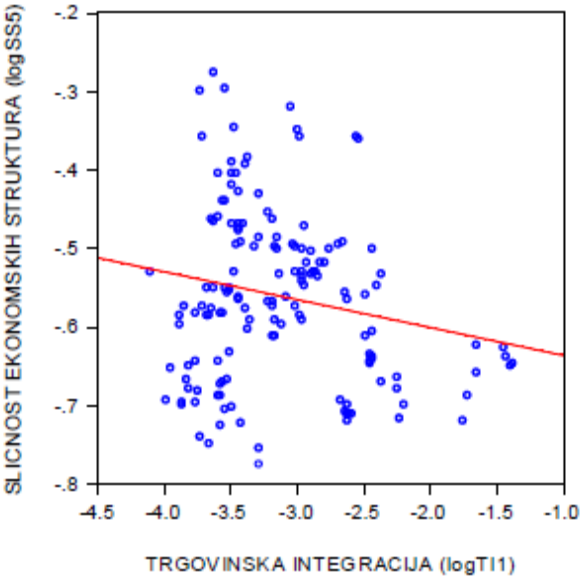
SLICNOST EKONOMSKIH STRUKTURA (logSS5)
-.2
-.3
-.4
-.5
-.6
-.7
-.8
-4.5
-4.0
-3.5
-3.0
-2.5
-2.0
-1.5
-1.0
TRGOVINSKA INTEGRACIJA (logTI1)

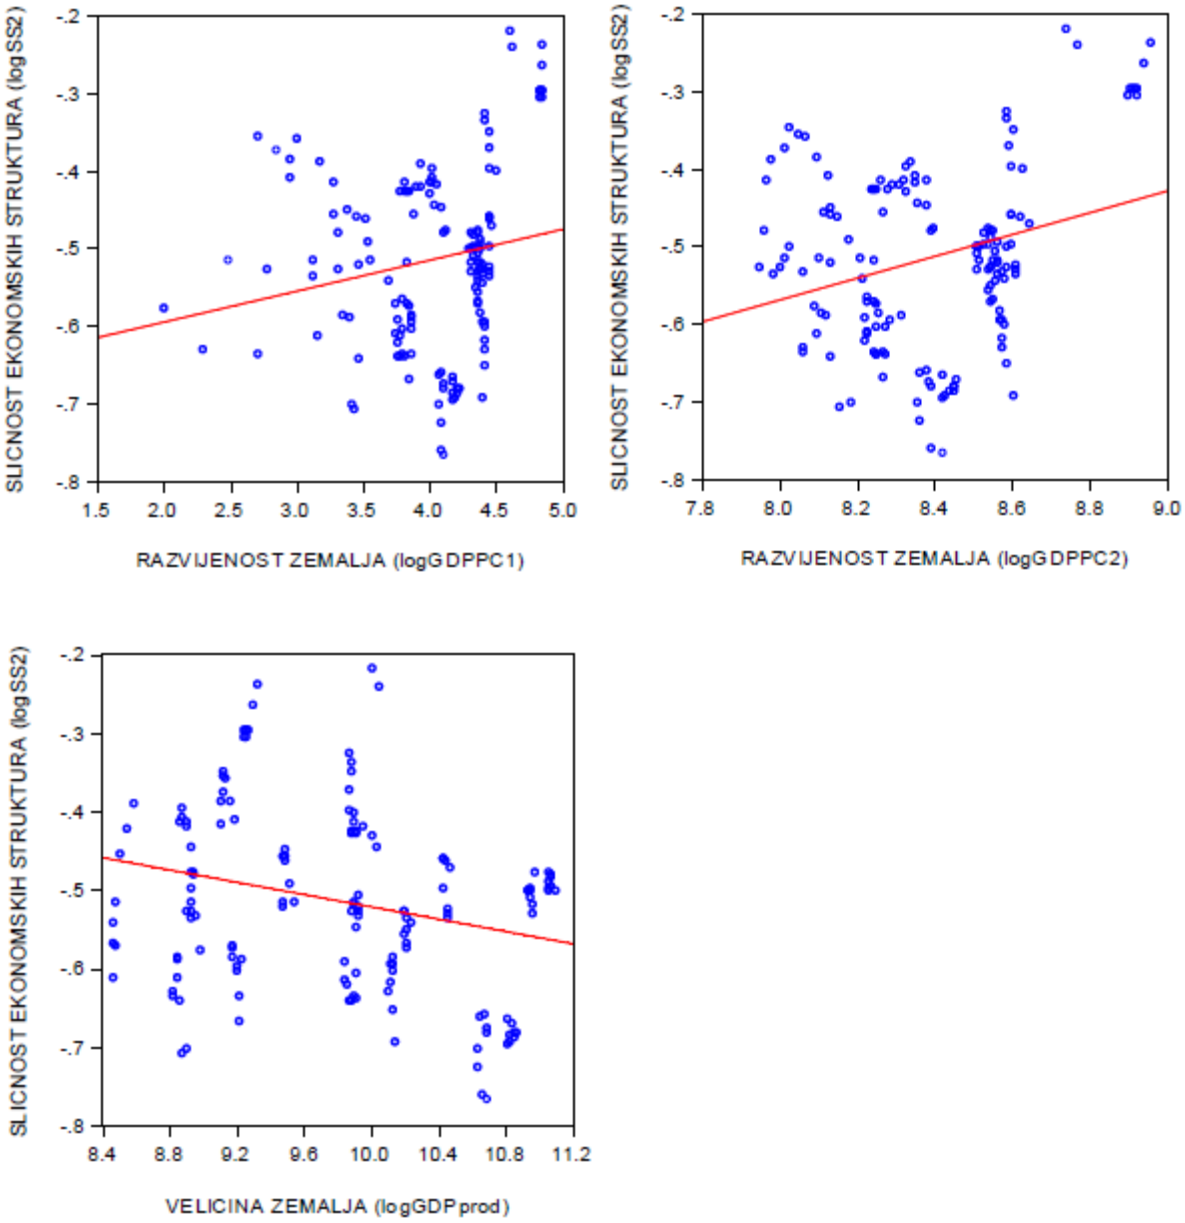

Izvor: Izrada autora (EViews 9)

Osim Studentovog t-testa, za panel 2a. (2001.-2008.) napravljeni su Wooldridgeov test i modificirani Waldov test u svrhu testiranja autokorelacije i heteroskedastičnosti reziduala (prikazani u tablici 12.). Wooldridgeov test potvrđuje da postoji autokorelacija reziduala, a modificirani Waldov test potvrđuje heteroskedastičnost reziduala.

Tablica 12. Wooldridgeov test i modificirani Waldov test logSS2 (2001.-2008.)

```
Wooldridge test for autocorrelation in panel data
H0: no first-order autocorrelation
    F(  1,      15) =     58.128
           Prob > F =      0.0000

Modified Wald test for groupwise heteroskedasticity
in fixed effect regression model

H0: sigma(i)^2 = sigma^2 for all i

chi2 (17)  =    4.7e+32
Prob>chi2 =      0.0000
```

Izvor: Izrada autora (Stata 14.2)

Isti testovi (prikazani u tablici 13.) napravljeni su za sličnost sektorskih struktura (logSS5) te također potvrđuju prisutnost autokorelacije i heteroskedastičnosti reziduala.

Tablica 13. Wooldridgeov test i modificirani Waldov test (logSS5) (2001.-2008.)

```
Wooldridge test for autocorrelation in panel data
H0: no first-order autocorrelation
    F(  1,      15) =     42.698
           Prob > F =      0.0000

Modified Wald test for groupwise heteroskedasticity
in fixed effect regression model

H0: sigma(i)^2 = sigma^2 for all i

chi2 (17)  =   16535.89
Prob>chi2 =      0.0000
```

Izvor: Izrada autora (Stata 14.2)

Za procjenu parametara u modelima kod kojih postoji autokorelacija i heteroskedastičnost reziduala Parks (1967) predlaže FGLS procjenitelj (engl. Feasible Generalized Least Squares). Međutim, FGLS procjenitelj nije prikladan za korištenje u panelima kod kojih je vremenska dimenzija veća od prostorne dimenzije (T>N) (Hoechle, 2007). U takvim slučajevima Beck i Katz (1995) predlažu korištenje PCSE (engl. panel-corrected standard error) procjenitelja. S obzirom da

je (u skladu s rezultatima Studentovog t-testa) kod panela 2. uzorak podijeljen na dva podrazdoblja (čime osnovni uvjet za korištenje FGLS procjenitelja nije zadovoljen), kod procjene parametara modela korišten je PCSE procjenitelj. U tablici 14. prikazani su rezultati panela 2a. koji obuhvaća razdoblje od 2001. do 2008. godine. Ukupno je testirano sedam modela.

Tablica 14. Rezultati panela 2a. (2001.-2008.)

	(1)	(2)	(3)	(4)	(5)	(6)	(7)
Sličnost sektorskih struktura (SS2)							
Trgovinska integracija (TI1)		-0.015 (0.012)	-0.032 (0.016)**		-0.030 (0.016)**	-0.032 (0.016)**	-0.028 (0.016)*
Trgovinska integracija (TI2)				-0.033 (0.015)**			
Financijska integracija (FI1)	0.018 (0.004)***		0.026 (0.007)***	0.025 (0.007)***	0.019 (0.008)***	0.026 (0.007)***	0.016 (0.008)**
Razvijenost zemalja (GDPPC1)					0.039 (0.016)**		0.060 (0.019)***
Veličina zemalja (GDPprod)						-0.012 (0.011)	-0.032 (0.012)***
constant	-0.486 (0.017)***	-0.595 (0.039)***	-0.557 (0.036)***	-0.653 (0.076)***	-0.731 (0.082)***	-0.439 (0.124)***	-0.511 (0.121)***

Robusne standardne greške prikazane su u zagradama

***, **, * označava statističku značajnost na razini 1%, 5% i 10%

Izvor: Izrada autora (Stata 14.2)

U svim testiranim modelima trgovinska integracija (TI1) ima negativan predznak što znači da pozitivno utječe na sličnost sektorskih struktura SS2 (zbog načina mjerenja sličnosti sektorskih struktura). Dakle, prema rezultatima panela, trgovinska integracija potiče konvergenciju sektorskih struktura Hrvatske i zemalja eurozone. Iz tablice 14. je vidljivo da je trgovinska

integracija statistički značajna na razini 5% u modelima (3), (5) i (6), statistički značajna na 10% u modelu (7), dok u modelu (2) nema statističke značajnosti. Dodatno, veličina koeficijenta u modelima varira od 0,015 do 0,032 što implicira da utjecaj nema ekonomsku značajnost. Rezultati panela su vrlo slični kad se za trgovinsku integraciju uzme TI2 (pozitivan, statistički značajan utjecaj na razini 5% pri čemu veličina koeficijenta iznosi 0,033). S obzirom da ovaj rezultat nije u skladu s očekivanim teorijskim preznakom potrebno ga je dodatno objasniti. Naime, indikator trgovinske integracije korišten u ovoj disertaciji ne pokazuje strukturu trgovine (tj. udio intraindustrijske i interindustrijske trgovine u ukupnoj trgovini), već isključivo obujam trgovine. To je vrlo bitna činjenica koju je potrebno uzeti u obzir prilikom tumačenja dobivenih rezultata. Dosadašnja provedena istraživanja potvrđuju da je većina hrvatske trgovinske razmjene interindustijskog tipa (Botrić i Broz, 2016; Derado, 2006; Škuflić i Vlahinić-Dizdarević, 2004) iz čega proizlazi da trgovinska integracija ne potiče konvergenciju sektorskih struktura Hrvatske i zemalja eurozone, već upravo suprotno – specijalizaciju u različitim sektorima. Stoga rezultat ovog panela proizlazi iz nedovoljno riješenih problema endogenosti i/ili (ne)stacionarnosti.

Financijska integracija (FI1) ima pozitivan predznak što znači da negativno utječe na sličnost sektorskih struktura zemalja. Dakle, financijska integracija potiče divergenciju sektorske strukture Hrvatske i sektorskih struktura zemalja eurozone. U svim modelima (osim modela (7)) financijska integracija statistički je značajna na razini 1%. Međutim iako postoji statistička značajnost, zbog veličine koeficijenta (koji varira od 0,016 do 0,026) može se zaključiti da ne postoji ekonomska značajnost utjecaja.

U testiranim modelima razvijenost zemalja (GDPPC1)[31] ima pozitivan predznak što znači da veća razlika u stupnju razvijenosti između Hrvatske i zemalja eurozone implicira veću razliku između njihovih sektorskih struktura. Dakle, Hrvatska ima sličniju sektorsku strukturu s nerazvijenijim zemljama eurozone. U modelu (7) navedeni utjecaj je statistički značajan na razini 1%, a u modelu (5) na razini 5%, pri čemu se zbog veličine koeficijenta (koja varira od 0,039 do 0,06) može zaključiti da navedeni utjecaj nema ekonomsku značajnost.

[31] GDPPC1 se mjeri apsolutnom razlikom bruto domaćih proizvoda po glavi stanovnika. Podaci o bruto domaćem proizvodu po glavi stanovnika preuzeti su iz baze podataka Eurostat.

Konačno, veličina zemalja (GDPprod)[32] ima negativan predznak što znači da pozitivno utječe na sličnost sektorskih struktura promatranih zemalja (zbog načina mjerenja SS5). Navedeni utjecaj može se objasniti činjenicom da veće zemlje imaju diversificiraniju sektorsku strukturu od manjih zemalja (koje su specijaliziranije, a time i osjetljivije na pojavu industrijski specifičnih šokova). Utjecaj je statistički značajan na razini 1% u modelu (7) dok u modelu (6) nije statistički značajan. Dodatno, veličina koeficijenta (koja varira od 0,012 do 0,032) potvrđuje da utjecaj nije ekonomski značajan.

U tablici 15. prikazani su rezultati panela 2b. (2001.-2008.) u kojem je korištena zavisna varijabla na nižoj razini agregacije - sličnost sektorskih struktura (SS5). Isto kao i kod panela 2a., zbog autokorelacije i heteroskedastičnosti reziduala korišten je PCSE procjenitelj. Ukupno je testirano sedam modela.

Tablica 15. Rezultati panela 2b. (2001.-2008.)

	(1)	(2)	(3)	(4)	(5)	(6)	(7)
Sličnost sektorskih struktura (SS5)							
Trgovinska integracija (TI1)		-0.018 (0.011)*	-0.031 (0.015)**		-0.029 (0.015)**	-0.0031 (0.015)**	-0.027 (0.015)*
Trgovinska integracija (TI2)				-0.037 (0.015)**			
Financijska integracija (FI1)	0.010 (0.006)*		0.019 (0.008)***	0.021 (0.008)***	0.013 (0.009)	0.020 (0.008)***	0.010 (0.009)
Razvijenost zemalja (GDPPC1)					0.035 (0.015)**		0.055 (0.019)***
Veličina zemalja (GDPprod)						-0.013 (0.010)	-0.031 (0.012)***

[32] GDPprod se mjeri produktom bruto domaćih proizvoda. Podaci o bruto domaćem proizvodu preuzeti su iz baze podataka Eurostat.

Constant	-0.558	-0.653	-0.624	-0.743	-0.777	-0.496	-0.557
	(0.025)***	(0.037)***	(0.034)***	(0.073)***	(0.078)***	(0.115)***	(0.115)***

Robusne standardne greške prikazane su u zagradama

***, **, * označava statističku značajnost na razini 1%, 5% i 10%

Izvor: Izrada autora (Stata 14.2)

Isto kao i kod panela 2a., u testiranim modelima trgovinska integracija (TI1) ima negativan predznak, što znači da trgovinska integracija potiče konvergenciju sektorskih struktura Hrvatske i zemalja eurozone[33] (pozitivno utječe na sličnost sektorskih struktura SS5)). Pri tome je utjecaj trgovinske integracije statistički značajan na razini 5% u modelima (3), (5) i (6), a statistički značajan na razini 10% u modelima (2) i (7). S obzirom na to da veličina koeficijenta u modelima varira od 0,018 do 0,031 može se zaključiti da navedeni utjecaj nema ekonomsku značajnost**.** Rezultati panela ne razlikuju se značajno kad se za varijablu trgovinske integracije koristi TI2 (pozitivan, statistički značajan utjecaj na razini 5% pri čemu veličina koeficijenta iznosi 0,037).

Financijska integracija (FI1) potiče divergenciju sektorske strukture Hrvatske od sektorskih struktura zemalja eurozone (negativno utječe na sličnost njihovih sektorskih struktura). U modelima (3), (4) i (6) koeficijent je statistički je značajan na razini 1%, pri čemu veličina koeficijenta (koja varira od 0,01 do 0,021) indicira da ne postoji ekonomska značajnost navedenog utjecaja.

Kao i kod panela 2a., u testiranim modelima panela 2b. razvijenost zemalja (GDPPC1) ima pozitivan predznak što znači da veća razlika u stupnju razvijenosti između Hrvatske i zemalja eurozone implicira veću razliku u njihovim sektorskim strukturama. Navedeni utjecaj je u modelu (7) statistički značajan na razini 1%, a u modelu (5) na razini 5%. Zbog veličine koeficijenta može se zaključiti da navedeni utjecaj nema ekonomsku značajnost.

Konačno, veličina zemalja (GDPprod) ima negativan predznak što (zbog načina mjerenja SS5) potvrđuje pozitivan utjecaj koji je statistički značajan na razini 1% u modelu (7). Dodatno, veličina koeficijenta pokazuje da utjecaj nije ekonomski značajan.

[33] Objašnjenje utjecaja isto kao i kod panela 2a

Isto kao i prije provođenja ekonometrijske panel analize za razdoblje od 2001. do 2008. godine, za razdoblje od 2009. do 2016. godine napravljeni su Wooldridgeov test autokorelacije reziduala i modificirani Waldov test. U tablici 16. prikazan je Wooldridgeov test autokrelacije reziduala (za zavisnu varijablu logSS2) koji potvrđuje da postoji autokorelacija reziduala. Modificirani Waldov test (također prikazan u tablici 16.) potvrđuje da postoji heteroskedastičnost reziduala.

Tablica 16. Wooldridgeov test i modificirani Waldov test (logSS2) (2009.-2016.)

```
Wooldridge test for autocorrelation in panel data
H0: no first-order autocorrelation
    F(  1,      16) =     17.535
           Prob > F =      0.0007

Modified Wald test for groupwise heteroskedasticity
in fixed effect regression model

H0: sigma(i)^2 = sigma^2 for all i

chi2 (19)  =    1759.62
Prob>chi2 =      0.0000
```

Izvor: Izrada autora (Stata 14.2)

U tablici 17. prikazan je Wooldridgeov test autokorelacije reziduala (za zavisnu varijablu logSS5) koji potvrđuje postojanje autokorelacije reziduala. Modificirani Waldov test (također prikazan u tablici 17.) potvrđuje da postoji heteroskedastičnost reziduala.

Tablica 17. Wooldridgeov test i modificirani Waldov test (logSS5) (2009.-2016.)

```
Wooldridge test for autocorrelation in panel data
H0: no first-order autocorrelation
    F(  1,      16) =     10.001
           Prob > F =      0.0060

Modified Wald test for groupwise heteroskedasticity
in fixed effect regression model

H0: sigma(i)^2 = sigma^2 for all i

chi2 (19)  =    1439.15
Prob>chi2 =      0.0000
```

Izvor: Izrada autora (Stata 14.2)

U tablici 18. prikazani su rezultati panela 2c. koji obuhvaća vremensko razdoblje od 2009. do 2016. godine. Ukupno je testirano sedam modela.

U svim testiranim modelima koeficijent trgovinske integracije (TI1) ima negativan predznak što znači da trgovinska integracija potiče konvergenciju sektorskih struktura Hrvatske i zemalja eurozone[34] (SS2). Pri tome je utjecaj u svim modelima statistički značajan na razini 1%. Dodatno, veličina koeficijenta trgovinske integracije u modelima varira od -0,042 do -0,103, što znači da kod promatranog utjecaja postoji ekonomska značajnost. Rezultati panela su vrlo slični kad se za varijablu trgovinske integracije koristi TI2 - pozitivan, statistički značajan utjecaj na razini 1%, pri čemu veličina koeficijenta iznosi -0,110.

Koeficijent financijske integracije (FI1) ima pozitivan predznak u svim testiranim modelima što znači da financijska integracija potiče divergenciju sektorskih struktura promatranih zemalja (negativno utječe na sličnost sektorskih struktura (SS2)). Dodatno, u svim testiranim modelima financijska integracija statistički je značajna na razini 1%. Na temelju veličine koeficijenta, koji varira od 0,021 do 0,101, može se zaključiti da postoji ekonomska značajnost utjecaja.

Dalje, što je veća razlika u stupnju razvijenosti (GDPPC1) manji je stupanj sličnosti sektorskih struktura promatranih zemalja (SS2). Međutim, utjecaj nije statistički značajan na razini 10%, a veličina koeficijenta potvrđuje da utjecaj nije ekonomski značajan. Kad se za varijablu razvijenosti zemalja koristi GDPPC2[35] utjecaj postaje statistički značajan na razini 5%, a veličina koeficijenta (0,120) potvrđuje ekonomsku značajnost utjecaja.

Rezultati analize panela 2c. potvrđuju važnost veličine zemlje za njezinu sektorsku strukturu. Naime, veličina zemalja (GDPprod) ima pozitivan utjecaj na sličnost sektorskih struktura zemalja (SS2). Kao što je već ranije rečeno, moguće objašnjenje rezultata je da veće (ekonomski snažnije) zemlje imaju diversificiraniju sektorsku strukturu od manjih zemalja (koje su u pravilu specijaliziranije od velikih zemalja). Utjecaj je statistički značajan na razini 1%, a veličina koeficijenta (-0,038) potvrđuje da utjecaj nije ekonomski značajan.

[34] Objašnjenje utjecaja isto kao i kod panela 2a
[35] GDPPC2 se mjeri produktom bruto domaćih proizvoda po glavi stanovnika. Podaci o bruto domaćem proizvodu po glavi stanovnika preuzeti su iz baze podataka Eurostat.

Tablica 18. Rezultati panela 2c. (2009.-2016.)

	(1)	(2)	(3)	(4)	(5)	(6)	(7)
Sličnost sektorskih struktura (SS2)							
Trgovinska integracija (TI1)		-0.042 (0.015)***	-0.103 (0.017)***		-0.103 (0.015)***	-0.089 (0.012)***	-0.048 (0.008)***
Trgovinska integracija (TI2)				-0.110 (0.016)***			
Financijska integracija (FI1)	0.021 (0.007)***		0.052 (0.009)***	0.050 (0.008)***	0.046 (0.008)***	0.034 (0.009)***	0.101 (0.015)***
Razvijenost zemalja (GDPPC1)					0.019 (0.024)		
Razvijenost zemalja (GDPPC2)						0.120 (0.051)**	
Veličina zemalja (GDPprod)							-0.038 (0.007)***
constant	-0.437 (0.031)***	-0.647 (0.047)***	-0.655 (0.033)***	-0.998 (0.072)***	-0.747 (0.109)***	-1.673 (0.441)***	-0.287 (0.080)***

Robusne standardne greške prikazane su u zagradama

***, **, * označava statističku značajnost na razini 1%, 5% i 10%

Izvor: Izrada autora (Stata 14.2)

Robusnost rezultata panela 2c. testirana je korištenjem sektorske strukture na nižoj razini agregacije (SS5) koja omogućava detaljniji uvid u sektorsku strukturu zemalja. U tablici 19. prikazani su rezultati panela 2d. koji (isto kao i panel 2c.) obuhvaća razdoblje od 2009. do 2016. godine. Ukupno je testirano sedam modela.

U svim testiranim modelima koeficijent trgovinske integracije (TI1) ima negativan predznak što znači da trgovinska integracija potiče konvergenciju sektorskih struktura promatranih zemalja[36] (SS5). Pri tome je utjecaj u svim modelima statistički značajan na razini 1%. Dodatno, veličina koeficijenta trgovinske integracije u modelima varira od -0,039 do -0,096, što upućuje na ekonomsku značajnost utjecaja. Rezultati panela su vrlo slični kad se za varijablu trgovinske integracije koristi TI2 - pozitivan, statistički značajan utjecaj na razini 1%, pri čemu veličina koeficijenta iznosi -0,105.

Koeficijent financijske integracije ima pozitivan predznak što znači da financijska integracija (FI1) potiče divergenciju sektorske strukture Hrvatske od sektorskih struktura zemalja eurozone (SS5). Dodatno, u svim testiranim modelima financijska integracija statistički je značajna na razini 1%. Na temelju veličine koeficijenta, koji varira od 0,020 do 0,048, može se zaključiti da ne postoji ekonomska značajnost utjecaja**.**

Dalje, što je veća razlika u stupnju razvijenosti između Hrvatske i zemalja eurozone (GDPPC1) manji je stupanj sličnosti njihovih sektorskih struktura (SS5). Utjecaj nije statistički značajan na razini 10%, a veličina koeficijenta (0,023) potvrđuje da utjecaj nije ekonomski značajan. Međutim, kad se za varijablu razvijenosti koristi GDPPC2 utjecaj postaje statistički značajan na razini 1%, a veličina koeficijenta (0,136) potvrđuje i ekonomsku značajnost utjecaja.

Rezultati analize panela 2d potvrđuju da veličina zemalja (GDPprod) utječe na sličnost njihovih sektorskih struktura (SS5), tj. ukazuje na pozitivan međuodnos veličine zemlje i stupnja njezine diversifikacije. Utjecaj je statistički značajan na razini 1%, a veličina koeficijenta (-0,029) potvrđuje da utjecaj nije ekonomski značajan.

[36] Objašnjenje utjecaja isto kao i kod panela 2a

Tablica 19. Rezultati panela 2d. (2009.-2016.)

	(1)	(2)	(3)	(4)	(5)	(6)	(7)
Sličnost sektorskih struktura (SS5)							
Trgovinska integracija (TI1)		-0.039 (0.014)***	-0.097 (0.016)***		-0.096 (0.014)***	-0.079 (0.012)***	-0.096 (0.014)***
Trgovinska integracija (TI2)				-0.105 (0.015)***			
Financijska integracija (FI1)	0.020 (0.008)***		0.048 (0.009)***	0.047 (0.008)***	0.041 (0.007)***	0.028 (0.009)***	0.046 (0.007)***
Razvijenost zemalja (GDPPC1)					0.023 (0.023)		
Razvijenost zemalja (GDPPC2)						0.136 (0.049)***	
Veličina zemalja (GDPprod)							-0.029 (0.007)***
constant	-0.484 (0.034)***	-0.686 (0.045)***	-0.695 (0.031)***	-1.025 (0.066)***	-0.805 (0.097)***	-1.854 (0.426)***	-0.415 (0.076)***

Robusne standardne greške prikazane su u zagradama

***, **, * označava statističku značajnost na razini 1%, 5% i 10%

Izvor: Izrada autora (Stata 14.2)

Na temelju prikazanih rezultata panela 1a. i 1b., te panela 2a., 2b., 2c. i 2d. prihvaća se hipoteza H2 koja navodi da financijska integracija putem specijalizacije neizravno negativno utječe na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone. Navedeni utjecaj u nastavku je objašnjen u kontekstu problema ove disertacije.

Financijska integracija omogućila je snažne kapitalne priljeve u Hrvatsku. Preciznije, u razdoblju od 2000. do 2008. godine priljev kapitala iznosio je prosječno oko 14% BDP-a, a u razdoblju od 2009. do 2014. godine smanjio se na prosječno oko 4% posto BDP-a; promatrajući strukturu

priljeva kapitala, iako su izravne strane investicije bile snažan izvor financiranja, domaća ekonomija oslanjala se više na dugovni kapital koji je iznosio oko 54% ukupnih priljeva (Bukovšak i ostali, 2017).

U takvoj situaciji (snažnih kapitalnih priljeva, a posebice dugovnog kapitala) došlo je do realne aprecijacije kune (iako se nominalni devizni tečaj u cijelom promatranom razdoblju kretao u relativno uskom rasponu od ±4%). Promjene u realnom efektivnom deviznom tečaju posljedica su bržeg rasta domaćih cijena u odnosu na strane cijene. Kretanje realnog efektivnog deviznog tečaja HRK/EUR prikazano je na grafikonu 13. (napomena: porast indeksa deviznog tečaja označava deprecijaciju). Davis (2015) ističe da je realna aprecijacija uglavnom povezana s dugovnim priljevima (a ne vlasničkim (engl. equity)), a primarno se objašnjava orijentacijom prema nerazmjenjivim sektorima (za razliku od vlasničkih priljeva koji su uglavnom više orijetirani prema razmjenjivim sektorima).

Grafikon 13. Realni i nominalni efektivni devizni tečaj

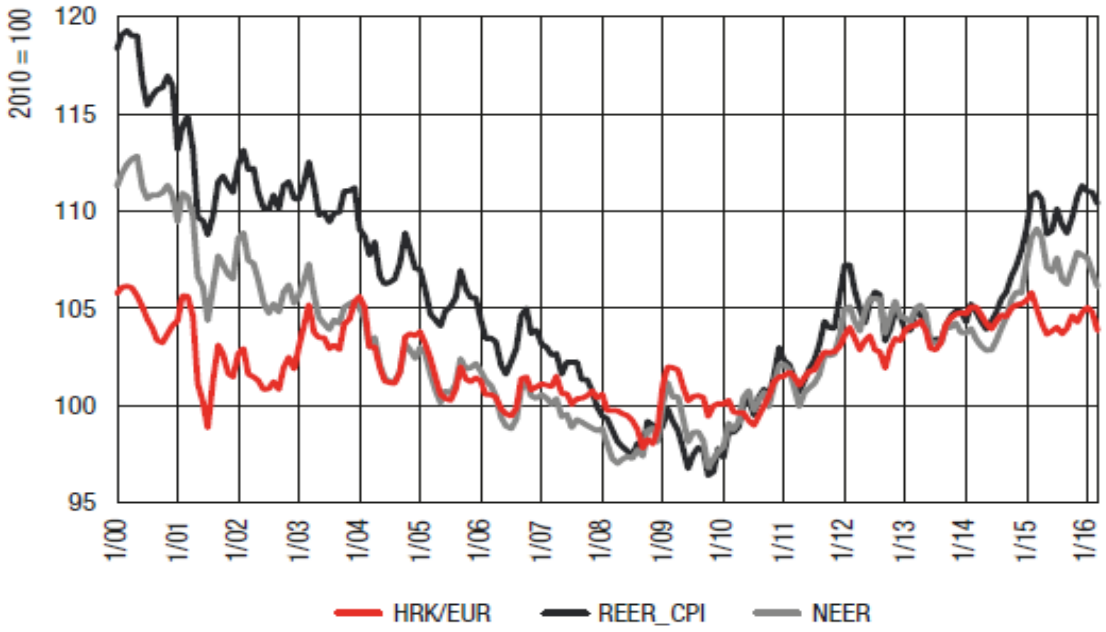

Izvor: Bukovšak i ostali (2017)

Bukovšak i ostali (2017) ističu da najistaknutiji učinak na aprecijaciju kune proizlazi iz zaduživanja drugih domaćih sektora (engl. other domestic sectors) što indicira da su sredstva većinom usmjerena prema nerazmjenjivim sektorima. Dodatno, tek nešto manje od jedne trećine akumuliranog priljeva izravnih stranih investicija u razdoblju od 1993. do 2016. otišlo je u proizvodni sektor, dok je ostatak otišao u poslovanje nekretninama, trgovinski i telekomunikacijski sektor (dakle, opet većina u nerazmjenjive sektore). Očigledno je aprecijacija realnog efektivnog deviznog tečaja pridonijela istiskivanju proizvodnih i izvoznih aktivnosti.

Na grafikonu 14. prikazana je bruto dodana vrijednost (u mil. eura) sektora hrvatske ekonomije u razdoblju od 2001. do 2016. godine. Crvenom linijom označeno je kretanje bruto dodane vrijednosti razmjenjivih sektora, a plavom bojom kretanje bruto dodane vrijednosti nerazmjenjivih sektora. Iz grafikona je vidljivo da u razdoblju snažnih priljeva kapitala dolazi do većeg rasta nerazmjenjivih sektora. Pomak od razmjenjivih prema nerazmjenjivim sektorima uzrokuje specijalizaciju hrvatske ekonomije, a takva specijalizacija usko je vezana uz dva osnovna problema.

Grafikon 14. Bruto dodana vrijednost sektora Hrvatske (2001.-2016.)

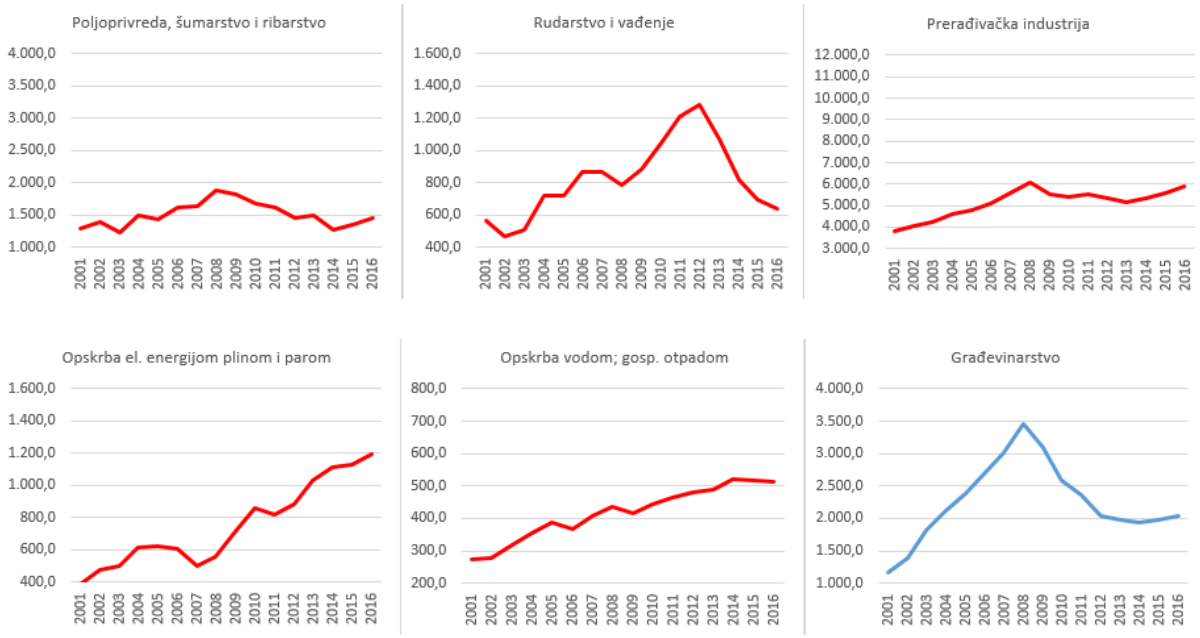

Trgovina na veliko i malo
8.000,0
7.000,0
6.000,0
5.000,0
4.000,0
3.000,0
2.000,0
2001 2002 2003 2004 2005 2006 2007 2008 2009 2010 2011 2012 2013 2014 2015 2016

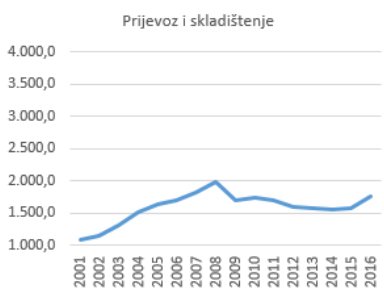
Prijevoz i skladištenje
4.000,0
3.500,0
3.000,0
2.500,0
2.000,0
1.500,0
1.000,0
2001 2002 2003 2004 2005 2006 2007 2008 2009 2010 2011 2012 2013 2014 2015 2016

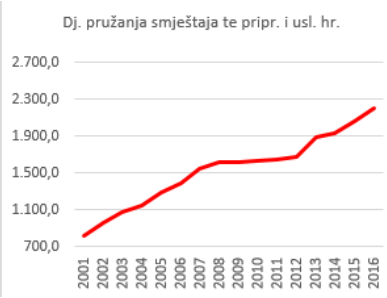
Dj. pružanja smještaja te pripr. i usl. hr.
2.700,0
2.300,0
1.900,0
1.500,0
1.100,0
700,0
2001 2002 2003 2004 2005 2006 2007 2008 2009 2010 2011 2012 2013 2014 2015 2016

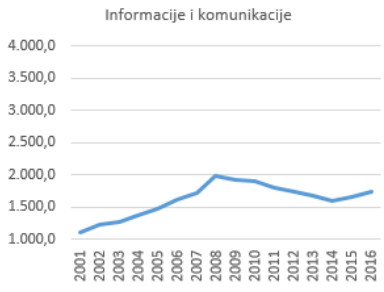
Informacije i komunikacije
4.000,0
3.500,0
3.000,0
2.500,0
2.000,0
1.500,0
1.000,0
2001 2002 2003 2004 2005 2006 2007 2008 2009 2010 2011 2012 2013 2014 2015 2016

Financijske djelatn. i djelatnosti osig.
4.000,0
3.500,0
3.000,0
2.500,0
2.000,0
1.500,0
1.000,0
2001 2002 2003 2004 2005 2006 2007 2008 2009 2010 2011 2012 2013 2014 2015 2016

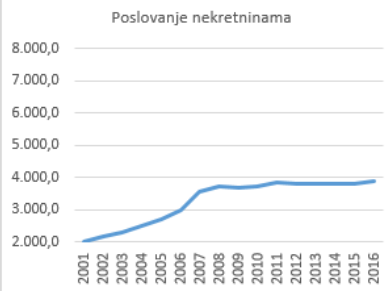
Poslovanje nekretninama
8.000,0
7.000,0
6.000,0
5.000,0
4.000,0
3.000,0
2.000,0
2001 2002 2003 2004 2005 2006 2007 2008 2009 2010 2011 2012 2013 2014 2015 2016

Stručne, znanstvene i tehničke djelat.
2.700,0
2.200,0
1.700,0
1.200,0
700,0
2001 2002 2003 2004 2005 2006 2007 2008 2009 2010 2011 2012 2013 2014 2015 2016

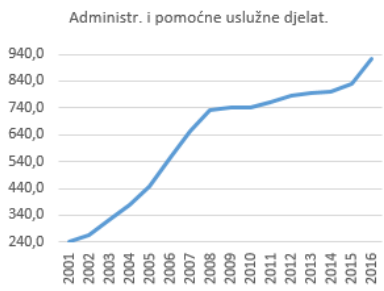
Administr. i pomoćne uslužne djelat.
940,0
840,0
740,0
640,0
540,0
440,0
340,0
240,0
2001 2002 2003 2004 2005 2006 2007 2008 2009 2010 2011 2012 2013 2014 2015 2016

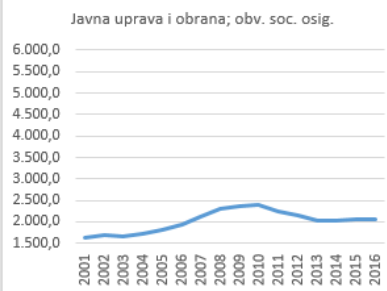
Javna uprava i obrana; obv. soc. osig.
6.000,0
5.500,0
5.000,0
4.500,0
4.000,0
3.500,0
3.000,0
2.500,0
2.000,0
1.500,0
2001 2002 2003 2004 2005 2006 2007 2008 2009 2010 2011 2012 2013 2014 2015 2016

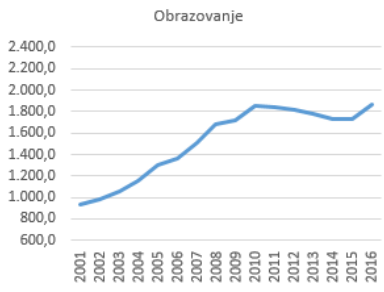
Obrazovanje
2.400,0
2.200,0
2.000,0
1.800,0
1.600,0
1.400,0
1.200,0
1.000,0
800,0
600,0
2001 2002 2003 2004 2005 2006 2007 2008 2009 2010 2011 2012 2013 2014 2015 2016

Djelatnosti zdrav. zaštite i soc. skrbi
4.000,0
3.500,0
3.000,0
2.500,0
2.000,0
1.500,0
1.000,0
2001 2002 2003 2004 2005 2006 2007 2008 2009 2010 2011 2012 2013 2014 2015 2016

Umjetnost, zabava i rekreacija
800,0
700,0
600,0
500,0
400,0
300,0
200,0
2001 2002 2003 2004 2005 2006 2007 2008 2009 2010 2011 2012 2013 2014 2015 2016

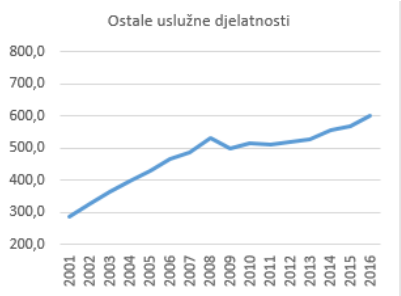

Izvor: Izrada autora

Prvo, općenito gledajući, specijalizacija povećava rizik od pojave idiosinkratskih šokova, a upravo su ti šokovi ključni problem valutnih područja. U prilog tome govori i činjenica da je stupanj diversifikacije prepoznat kao jedan od temeljnih kriterija u teoriji optimalnih valutnih područja (Kenen, 1969). Strogo teorijski gledano, sektorska specijalizacija ne mora nužno biti problem ako postoje odgovarajući mehanizmi apsorpcije idiosinkratskih šokova. Međutim, rigidnost cijena i plaća (Kunovac i Pufnik, 2015), ograničenja u provođenju fiskalne politike (Šimović, Ćorić i Deskar-Škrbić, 2014) te nedovoljno snažni kanali podjele rizika (potvrđeni u prvoj hipotezi) upućuju na nedjelotvornost navedenih mehanizama u Hrvatskoj. U skladu s time, očekivano je da sektorska specijalizacija uzrokuje divergenciju poslovnog ciklusa Hrvatske od poslovnih ciklusa zemalja eurozone, što je i potvrđeno u panelu 1b.

Drugo, sektorska specijalizacija koja u Hrvatskoj (pod utjecajem snažnih priljeva kapitala) ide od razmjenjivih prema nerazmjenjivim sektorima ima negativne posljedice na gospodarski rast. Naime, Benigno i Fornaro (2014) ističu da su razmjenjivi sektori motor rasta, i da se produktivnost povećava s povećanjem udjela radnika zaposlenih u razmjenjivim sektorima.

Europska komisija (2015) ističe da je Hrvatska u razdoblju od 2002. do 2013. godine imala relativno slabi rast produktivnosti (prikazano na grafikonu 15.) koji je bio prikriven i djelomično neutraliziran snažnim priljevom kapitala i optimističnim vanjskim okruženjem prije krize. Međutim, slabi temelji rasta potpuno su izašli na vidjelo sa smanjenjem pozitivnih čimbenika potražnje.

Problem slabog rasta produktivnosti dodatno je povećan specijalizacijom od razmjenjivog prema nerazmjenjivom sektoru. Dakle, vidljiv je problem ovakvog oblika specijalizacije koji

(dugoročno) uzrokuje divergentne stopa rasta Hrvatske i zemalja eurozone te na taj način smanjuje usklađenost njihovih poslovnih ciklusa.

Gelo i Družić (2015) ističu da je, s obzirom na stanje hrvatskoga gospodarstva, potrebno povećavati kako udio, tako i produktivnost rada sektora s međunarodno razmjenjivim dobrima.

Grafikon 15. Izračun rasta - prosjek za 2002.-2008. (%); prosjek za 2008.-2013. (%)

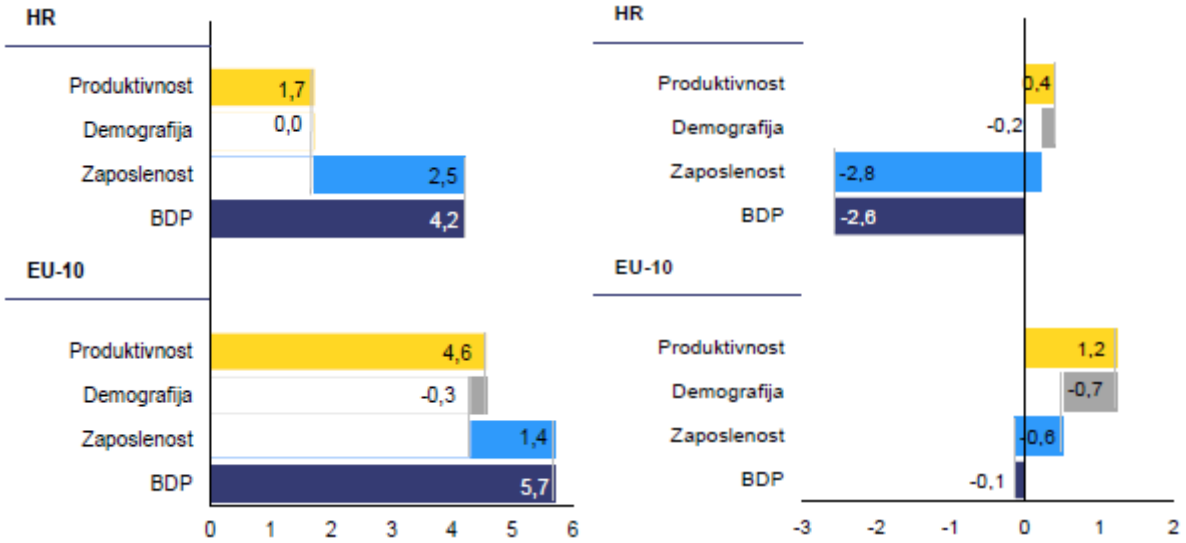

Izvor: Europska komisija (2015)

Panel 3.

Panelom 3. analizira se utjecaj financijske integracije na trgovinsku integraciju Hrvatske sa zemljama eurozone s ciljem potvrđivanja pomoćne hipoteze H31. Rezultati Studentovog t-testa zavisne varijable (logTI1) prikazani u tablici 20. potvrđuju da ne postoji razlika aritmetičkih sredina u razdoblju prije krize (2001. – 2008.) i kriznom te postkriznom razdoblju (2009. – 2016.). Stoga uzorak nije potrebno dijeliti na dva dijela, već će se ekonometrijska analiza panela 3. provesti na cijelom uzorku.

Tablica 20. T-test jednakosti artimetičkih sredina zavisne varijable (logTI1) panela 3.

Two-sample t test with equal variances

Variable	Obs	Mean	Std. Err.	Std. Dev.	[95% Conf.	Interval]
logTI1~8	152	-3.211626	.0513674	.6333003	-3.313118	-3.110135
logTI1~6	152	-3.119964	.0475041	.5856703	-3.213823	-3.026106
combined	304	-3.165795	.0350244	.6106709	-3.234717	-3.096874
diff		-.0916618	.0699661		-.2293447	.046021

```
    diff = mean(logTI10108) - mean(logTI10916)                    t =  -1.3101
Ho: diff = 0                                     degrees of freedom =      302

    Ha: diff < 0                 Ha: diff != 0                 Ha: diff > 0
 Pr(T < t) = 0.0956         Pr(|T| > |t|) = 0.1912          Pr(T > t) = 0.9044
```

Izvor: Izrada autora

S obzirom da će se analiza robusnosti rezultata panela 3. napraviti korištenjem logTI2 kao zavisne varijable, napravljen je Studentov t-test jednakosti aritmetičkih sredina za log TI2 za razdoblje prije krize (2001. – 2008.) i krizno te postkrizno razdoblje (2009.-2016.). U tablici 21. prikazani su rezultati testa koji potvrđuju da ne postoji razlika aritmetičkih sredina između razdoblja prije krize (2001. – 2008.) i kriznog te postkriznog razdoblja (2009. – 2016.). Stoga uzorak nije potrebno dijeliti na dva dijela, već se ekonometrijska analiza panela 3. može provesti na cijelom uzorku.

Tablica 21. T-test jednakosti artimetičkih sredina zavisne varijable (logTI2) panela 3.

Two-sample t test with equal variances

Variable	Obs	Mean	Std. Err.	Std. Dev.	[95% Conf.	Interval]
logTI2~8	152	-6.030988	.0511417	.6305175	-6.132034	-5.929942
logTI2~6	152	-5.960575	.0455431	.5614929	-6.050559	-5.870591
combined	304	-5.995782	.0342437	.5970599	-6.063167	-5.928396
diff		-.0704125	.068481		-.2051728	.0643479

```
    diff = mean(logTI20108) - mean(logTI20916)                    t =  -1.0282
Ho: diff = 0                                     degrees of freedom =      302

    Ha: diff < 0                 Ha: diff != 0                 Ha: diff > 0
 Pr(T < t) = 0.1523         Pr(|T| > |t|) = 0.3047          Pr(T > t) = 0.8477
```

Izvor: Izrada autora (Stata 14.2)

Na grafikonu 16. prikazani su dijagrami rasipanja za panel 3. Iz dijagrama rasipanja vidljivo je da regresijski pravac međuodnosa financijske integracije (logFI1) i trgovinske integracije (log TI1) ima pozitivan nagib, a nagib pravca ne mijenja se značajno ni kad se za trgovinsku integraciju koristi logTI2**.** Potvrđuje se snažna pozitivna linearna veza između financijske integracije i trgovinske integracije Hrvatske sa zemljama eurozone. Međutim, kad se za financijsku integraciju koristi logFI3, regresijski pravac ima manji nagib.

Regresijski pravac međuodnosa trgovinske integracije (logTI1) i razvijenosti zemalja (logGDPPC1) ima pozitivan nagib. Regresijski pravac ne mijenja značajno nagib s promjenom načina mjerenja razvijenosti zemalja (logGDPPC2). Konačno, vidljivo je da regresijski pravac međuodnosa veličine zemalja (logGDPprod) trgovinske integracije (logTI1) ima pozitivan nagib čime se potvrđuje pozitivna linearna veza između veličine zemalja i njihove trgovinske integracije.

Grafikon 16. Dijagrami rasipanja FI-TI

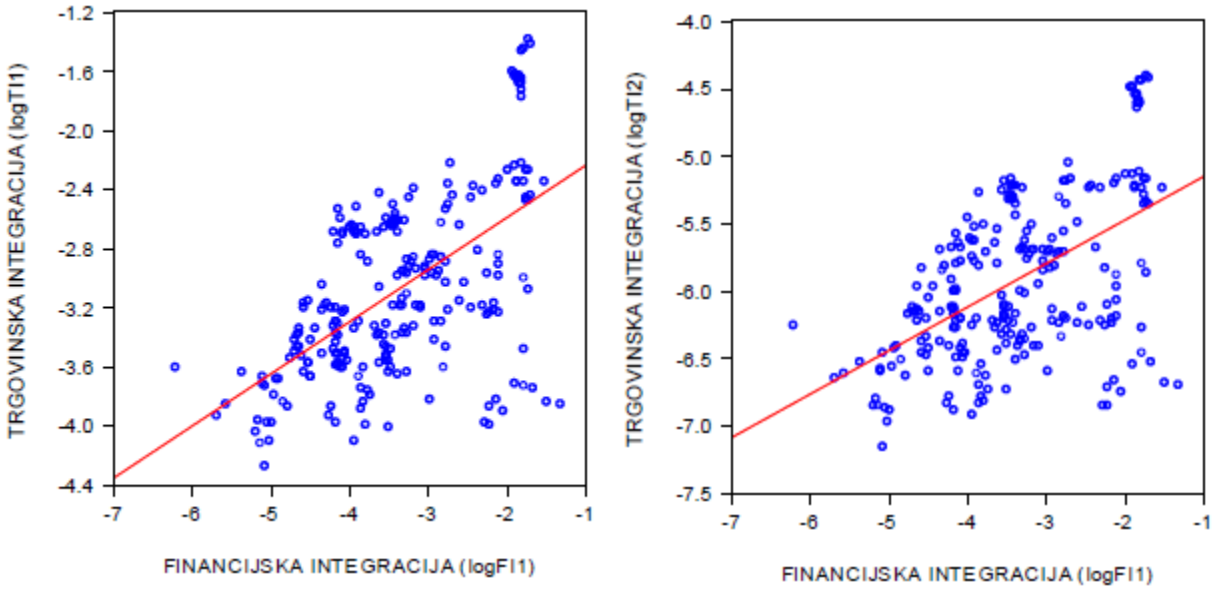

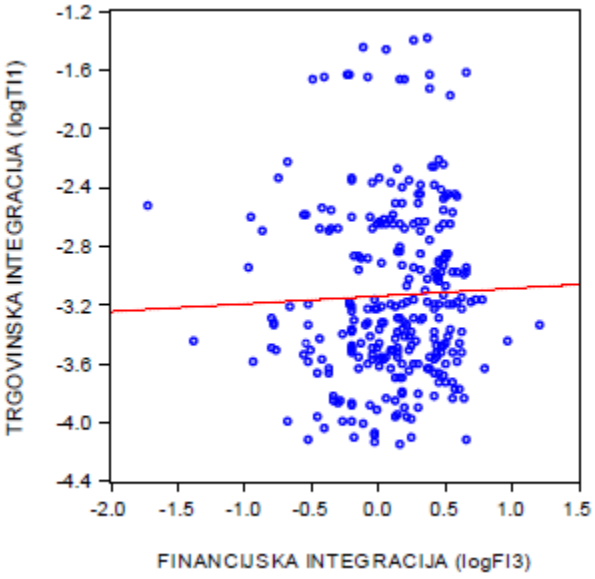
TRGOVINSKA INTEGRACIJA (logTI1)
FINANCIJSKA INTEGRACIJA (logFI3)

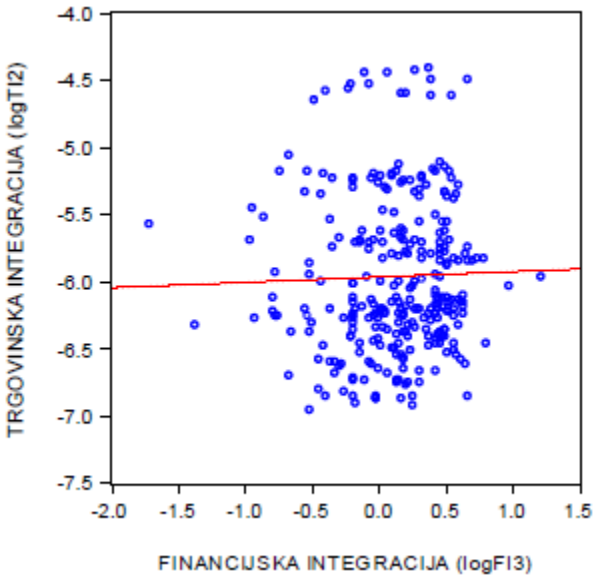
TRGOVINSKA INTEGRACIJA (logTI2)
FINANCIJSKA INTEGRACIJA (logFI3)

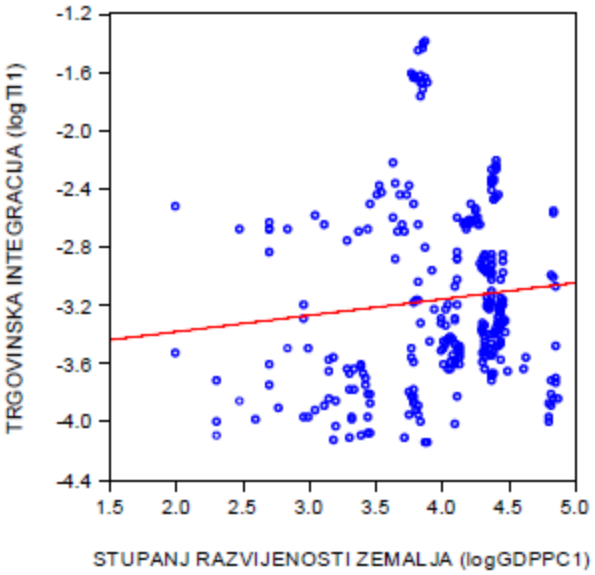
TRGOVINSKA INTEGRACIJA (logTI1)
STUPANJ RAZVIJENOSTI ZEMALJA (logGDPPC1)

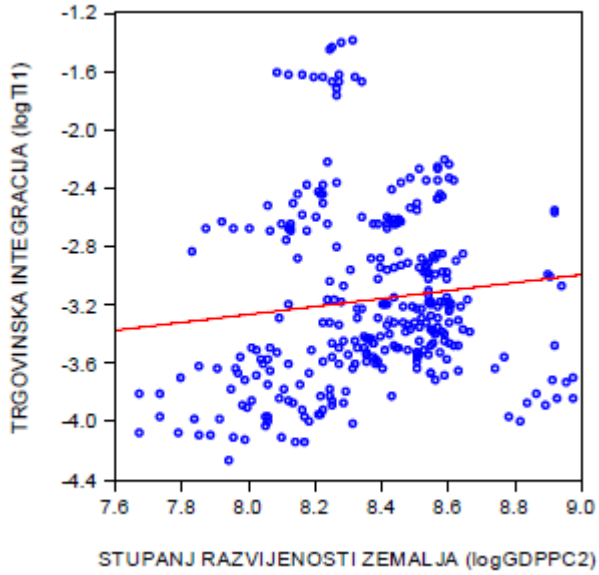
TRGOVINSKA INTEGRACIJA (logTI1)
STUPANJ RAZVIJENOSTI ZEMALJA (logGDPPC2)

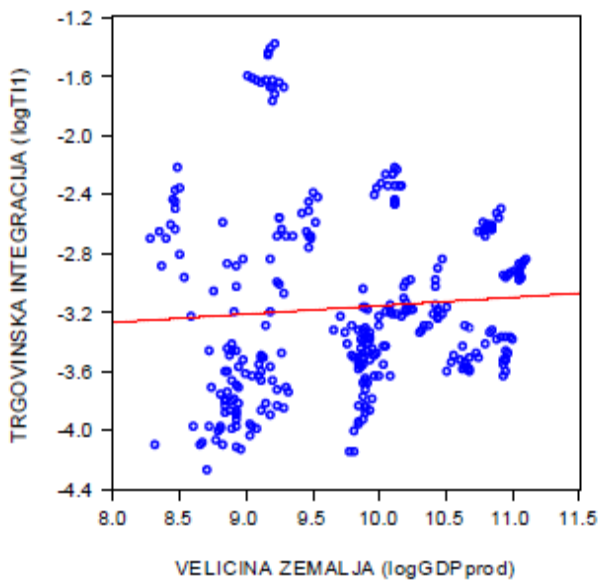

Izvor: Izrada autora (EViews 9)

Isto kao i kod ekonometrijske analize panela 1., velika vremenska dimenzija u odnosu na prostornu dimenziju u panelu 3a. isključuje mogućnost korištenja dinamičkog panela (Arelano-Bond GMM). Stoga će se analiza provesti korištenjem statičkog panela, a izbor prikladnog učinka (fiksnog ili slučajnog učinka) određen je Hausmanovim testom. Rezultati Hausmanovog testa prikazani su u tablici 22.

Tablica 22. Hausmanov test (logTI1)

	Coefficients			
	(b) fe	(B) re1	(b-B) Difference	sqrt(diag(V_b-V_B)) S.E.
logFI1	.1248172	.1623823	-.037565	.0102292
logSS2	-.2600115	-.4885133	.2285018	.0791416
logGDPPC1	.0158945	.0041818	.0117127	.0245753

b = consistent under Ho and Ha; obtained from xtreg
B = inconsistent under Ha, efficient under Ho; obtained from xtreg

Test: Ho: difference in coefficients not systematic

chi2(3) = (b-B)'[(V_b-V_B)^(-1)](b-B)
= 15.61
Prob>chi2 = 0.0014

Izvor: Izrada autora (Stata 14.2)

Rezultati Hausmanovog testa potvrđuju prikladnost korištenja statičkog panela s fiksnim učinkom. Potencijalni problem autokorelacije reziduala testiran je Wooldridgeovm testom čiji rezultati (prikazani u tablici 23.) potvrđuju da u panelu 3a. ne postoji problem autokorelacije reziduala. Osim na autokorelaciju reziduala, panel 3a. testiran je i na heteroskedastičnost reziduala putem modificiranog Waldovog testa. Rezultati testa (također prikazani u tablici 23.) ukazuju na heteroskedastičnost reziduala koja je uklonjena korištenjem Eicker-Huber-Whiteovog procjenitelja.

Tablica 23. Wooldridgeov test autokorelacije i modificirani Waldov test (logTI1)

```
Wooldridge test for autocorrelation in panel data
H0: no first-order autocorrelation
    F(  1,       18) =      0.003
           Prob > F =      0.9563

Modified Wald test for groupwise heteroskedasticity
in fixed effect regression model

H0: sigma(i)^2 = sigma^2 for all i

chi2 (19)  =    6115.47
Prob>chi2 =      0.0000
```

Izvor: Izrada autora (Stata 14.2)

Robusnost rezultata panela 3a. testirana je korištenjem logTI2 kao zavisne varijable u empirijskom modelu. Prije provođenja ekonometrijske analize (procjene parametara modela) panela 3b. napravljeni su isti testovi kao i kod panela 3a. Rezultati Hausmanovog testa (prikazani u tablici 24.) potvrđuju prikladnost korištenja statičkog panela s fiksnim učinkom.

Tablica 24. Hausmanov test (logTI2)

	Coefficients (b) fe	(B) re	(b-B) Difference	sqrt(diag(V_b-V_B)) S.E.
logFI1	.1082758	.1393627	-.0310868	.0100641
logSS2	-.3333874	-.5352583	.2018709	.0783519
logGDPPC1	-.0424859	-.0353647	-.0071212	.0239692

b = consistent under Ho and Ha; obtained from xtreg
B = inconsistent under Ha, efficient under Ho; obtained from xtreg

Test: Ho: difference in coefficients not systematic

chi2(3) = (b-B)'[(V_b-V_B)^(-1)](b-B)
= 10.01
Prob>chi2 = 0.0185

Izvor: Izrada autora

Rezultati Wooldridgeovog testa (prikazani u tablici 25.) potvrđuju da u promatranom modelu ne postoji problem autokorelacije reziduala. Međutim, rezultat modificiranog Waldovog testa (također prikazan u tablici 25.) ukazuje na problem heteroskedastičnosti reziduala. Navedeni problem riješen je korištenjem Eicker-Huber-Whiteovog procjenitelja.

Tablica 25. Wooldridgeov test autokorelacije i modificirani Waldov test (logTI2)

Wooldridge test for autocorrelation in panel data
H0: no first-order autocorrelation
F(1, 18) = 0.073
Prob > F = 0.7898

Modified Wald test for groupwise heteroskedasticity
in fixed effect regression model

H0: sigma(i)^2 = sigma^2 for all i

chi2 (19) = 18457.44
Prob>chi2 = 0.0000

Izvor: Izrada autora (Stata 14.2)

U tablici 26. prikazani su rezultati panela 3a. Ukupno je prikazano šest modela.

U svim testiranim modelima financijska integracija (FI1) ima pozitivan predznak što znači da financijska integracija potiče trgovinsku integraciju (TI1) Hrvatske sa zemljama eurozone. Pri tome je utjecaj u modelima (4) i (5) statistički značajan na razini 1%, a u ostalim testiranim modelima utjecaj je statistički značajan na razini 10%. Dodatno, veličina koeficijenta financijske integracije u modelima varira od 0,084 do 0,129 što znači da postoji ekonomska značajnost navedenog utjecaja.

Iako sličnost sektorskih struktura (SS2) ima negativan predznak s poprilično velikim koeficijentom (koji varira od -0,260 do -0,355), utjecaj nije statistički značajan na razini 10% ni u jednom od testiranih modela. Situacija se ne mijenja značajno ni s promjenom načina mjerenja sličnosti sektorskih struktura (SS5) što potvrđuje robusnost rezultata.

Razvijenost zemalja (GDPPC1) ima pozitivan predznak što znači da pozitivno utječe na trgovinsku integraciju Hrvatske sa zemljama eurozone. Navedeni utjecaj indicira da Hrvatska više trguje s razvijenijim zemljama eurozone. Međutim, utjecaj nije statistički značajan na razini 10%. Razvijenost zemalja (GDPPC2) pozitivno utječe na trgovinsku integraciju u svim testiranim modelima, pri čemu je utjecaj statistički značajan na razini 1%. Iz veličine koeficijenta (koji varira između 0,531 i 0,548) može se zaključiti da navedeni utjecaj ima ekonomsku značajnost.

Iako ima pozitivan predznak u svim testiranim modelima, utjecaj veličine zemalja (GDPprod) na trgovinsku integraciju (TI1) nije statistički značajan na razini 10%. Navedeni utjecaj implicira da veličina zemalja eurozone (kao trgovinskih partnera) nema važnu ulogu u trgovinskoj razmjeni s Hrvatskom, već je za intenzitet trgovinske razmjene važniji stupanj razvijenosti.

Tablica 26. Rezultati panela 3a.

	(1)	(2)	(3)	(4)	(5)	(6)
Trgovinska integracija (TI1)						
Financijska integracija (FI1)	0.084 (0.454)*	0.086 (0.048)*	0.097 (0.049)*	0.125 (0.043)***	0.129 (0.047)***	0.094 (0.046)*
Sličnost sektorskih struktura (SS2)	-0.355 (0.334)			-0.260 (0.306)		-0.307 (0.329)
Sličnost sektorskih struktura (SS5)		-0.503 (0.418)	-0.460 (0.416)		-0.401 (0.403)	
Razvijenost zemalja (GDPPC1)				0.016 (0.065)	0.022 (0.062)	
Razvijenost zemalja (GDPPC2)	0.531 (0.177)***	0.548 (0.180)***				
Veličina zemalja (GDPprod)			0.381 (0.229)			0.363 (0.224)
constant	-7.428 (1.597)***	-7.672 (1.627)***	-6.752 (2.347)***	-2.845 (0.364)***	-2.950 (0.357)***	-6.485 (2.295)***

Robusne standardne greške prikazane su u zagradama

***, **, * označava statističku značajnost na razini 1%, 5% i 10%

Izvor: Izrada autora

Robusnost rezultata panela 3a. testirana je korištenjem TI2 za zavisnu varijablu. Rezultati panela 3b. sa zavisnom varijablom TI2 prikazani su u tablici 27. Ukupno je testirano šest modela. Vidljivo je da su rezultati panela 3b. vrlo slični rezultatima panela 3a. čime se potvrđuje robusnost rezultata panela 3a.

Tablica 27. Rezultati panela 3b.

	(1)	(2)	(3)	(4)	(5)	(6)
Trgovinska integracija (TI2)						
Financijska integracija (FI1)	0.093 (0.048)*	0.097 (0.051)*		0.108 (0.047)**	0.114 (0.051)**	0.092 (0.049)*
Sličnost sektorskih struktura (SS2)	-0.393 (0.297)			-0.333 (0.273)		-0.381 (0.294)
Sličnost sektorskih struktura (SS5)		-0.599 (0.369)	-0.356 (0.330)		-0.527 (0.351)	
Razvijenost zemalja (GDPPC1)				-0.042 (0.060)	-0.035 (0.056)	
Razvijenost zemalja (GDPPC2)	0.206 (0.179)	0.232 (0.181)	0.555 (0.178)***			
Veličina zemalja (GDPprod)						0.184 (0.246)
constant	-7.541 (1.621)***	-7.881 (1.648)***	-10.848 (1.605)***	-5.549 (0.351)***	-5.690 (0.333)***	-7.61 (2.530)***

Robusne standardne greške prikazane su u zagradama

***, **, * označava statističku značajnost na razini 1%, 5% i 10%

Izvor: Izrada autora

U svim testiranim modelima financijska integracija (FI1) ima pozitivan predznak što znači da financijska integracija potiče trgovinsku integraciju (TI2) Hrvatske sa zemljama eurozone. Pri tome je utjecaj u modelima (4) i (5) statistički značajan na razini 5%, a u ostalim testiranim modelima utjecaj je statistički značajan na razini 10%. Dodatno, veličina koeficijenta financijske integracije (FI1) u modelima varira od 0,092 do 0,114 što znači da postoji ekonomska značajnost utjecaja.

Sličnost sektorskih struktura (SS2) ima negativan predznak što znači da (zbog načina mjerenja) pozitivno utječe na trgovinsku integraciju (TI2). Iako je koeficijent poprilično velik (varira od -0,333 do -0393), utjecaj nije statistički značajan na razini 10% ni u jednom od testiranih modela. Situacija se ne mijenja značajno ni s promjenom načina mjerenja sličnosti sektorskih struktura (SS5) što potvrđuje robusnost rezultata.

Dalje, rezultati panela 3b. pokazuju da utjecaj razvijenosti zemalja na trgovinsku integraciju ovisi o načinu mjerenja varijable razvijenost zemalja. Razvijenost zemalja (GDPPC1) negativno utječe na trgovinsku integraciju u svim testiranim modelima. Međutim, utjecaj nije statistički značajan na razini 10%. S druge strane razvijenost zemalja (GDPPC2) pozitivno utječe na trgovinsku integraciju, pri čemu utjecaj u modelima (1) i (2) nije statistički značajan na razini 10%, dok je u modelu (3) statistički značajan na razini 1%.

Konačno, iako pozitivnog predznaka, utjecaj veličine zemalja (GDPprod) na trgovinsku integraciju (TI2) nije statistički značajan na razini 10%.

Na temelju prikazanih rezultata panela 1a. i 1b. te panela 3a. i 3b. prihvaća se hipoteza H3 koja pretpostavlja da financijska integracija neizravno pozitivno utječe na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone kroz jačanje trgovinske integracije.

Navedeni utjecaj potrebno je objasniti u kontekstu pojave makroekonomskih neravnoteža uzrokovanih financijskom integracijom. Naime, financijska integracija potaknula je snažni rast domaće potražnje koja je zadovoljena uvozom i to poglavito iz zemalja eurozone. Na grafikonu 17. vidljivo je da u pretkriznom razdoblju dolazi do snažne robne razmjene. Međutim, iako trgovinska integracija raste, istovremeno dolazi do snažnijeg rasta uvoza od rasta izvoza što uzrokuje deficit na računu roba.

Rogić (2011) ističe da je Hrvatska u većini promatranog razdoblja imala snažan deficit tekućeg računa bilance plaćanja, a najveći doprinos pogoršanju salda imao je upravo deficit na računu roba. Naime, hrvatski deficit na računu roba povećao se s 14,96% BDP-a u 2000. godini na 22,59% BDP-a u 2008. godini, da bi se s pojavom krize do 2010. godine taj udio smanjio do 12,94%.

Grafikon 17. Robna razmjena Hrvatske sa zemljama eurozone u mil. eura (2001.-2016.)

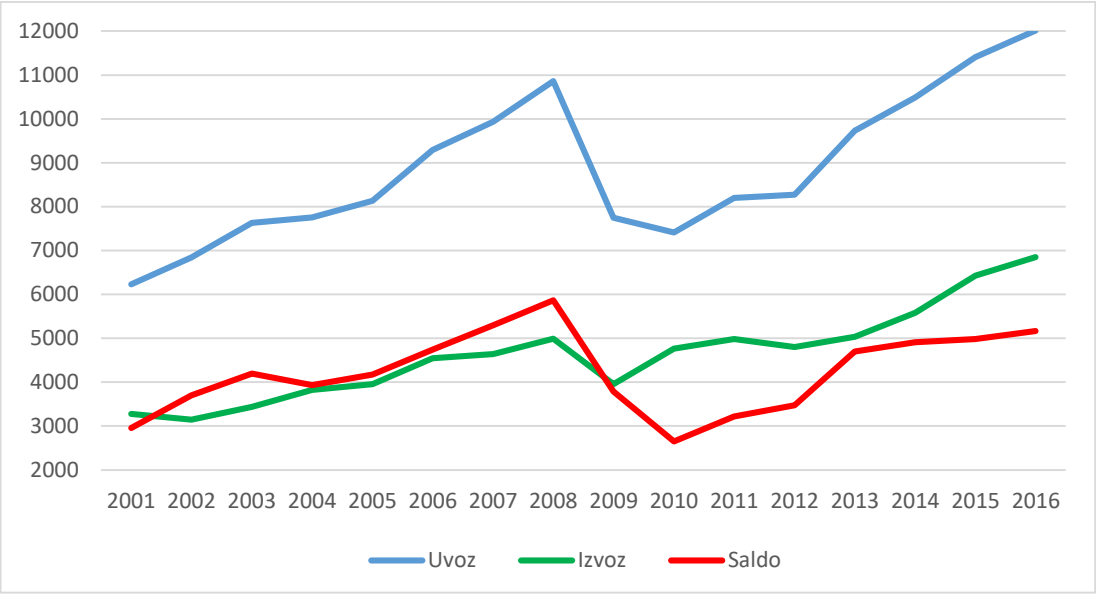

Izvor: Izrada autora

Lane i Milesi-Ferreti (2012) ističu da je odnos između financijske integracije i neravnoteža bilanci plaćanja jedna od glavnih značajki pretkriznog globalnog okruženja. Masivni priljevi kapitala potiču stvaranje imovinskih balona (engl. asset booms), jeftino kreditiranje i pretjerano investiranje u zemljama primateljicama (Lane i Milesi-Ferreti, 2014).

Iako Pasimeni (2015) ističe da se akumulacija vanjskih neravnoteža zemalja eurozone prije krize često u literaturi objašnjava troškovnom konkurentnošću, tj. divergentnim jediničnim troškovima rada, u slučaju Hrvatske ipak se vjerojatnije radi o drugačijem objašnjenju.

Naime, s pojavom krize dolazi do naglog smanjivanja robnog deficita (u razdoblju od 2008. do 2010. godine robni deficit je pao s 5,87 milijardi eura na 2,65 milijardi eura) koji se ne može racionalno objasniti smanjenjem jediničnih troškova rada (jedinični troškovi rada usko su povezani s kretanjem realnog efektivnog deviznog tečaja prikazanog na grafikonu 13.). Osim toga iz grafikona 17. vidljivo je da u razdoblju od 2008. do 2010. godine ne dolazi do rasta robnog izvoza, već se deficit robnog salda smanjuje zahvaljujući drastičnom padu robnog uvoza (s 10,86

milijardi eura na 7,41 milijardu eura). Navedeno implicira da su promjene u potražnji ključne u objašnjavanju hrvatskih neravnoteža na tekućem računu bilance plaćanja.

Hrvatski model rasta očigledno se temelji na snažnoj domaćoj potražnji potaknutoj dugovnim kapitalnim priljevima omogućenim financijskom integracijom, a kao takav inherentno je podložan stvaranju vanjskih neravnoteža (deficita na tekućem računu bilance plaćanja). Naknadna prilagodba na vanjske neravnoteže ostvarena je drastičnim smanjenjem domaće potražnje (uvoza). Dakle, nakon pretkriznog razdoblja u kojem financijska integracija potiče trgovinsku integraciju i usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone, 2008. godine dolazi do pada trgovinske integracije te divergencije poslovnog ciklusa Hrvatske i zemalja eurozone (iz čega proizlazi pozitivan utjecaj trgovinske integracije na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone u potvrđen u panelima 1a. i 1b.).

Fundamentalni problem leži u različitim modelima rasta između Hrvatske koja ima tzv. dugovni model rasta (engl. debt led); i dijela zemalja eurozone (pretežno zemlje jezgre eurozone) koje imaju izvozni (engl. export led) model rasta. Iako oba modela omogućavaju rast, Stockhammer i Kohler (2019) ističu da su modeli intrinzično nestabilni jer zahtijevaju povećanje duga u odnosu na dohodak – u slučaju dugovnog modela domaći privatni dug, a u slučaju izvoznog modela strani dug trgovinskih partnera. Kod dugovnog modela razduživanjem nestaju učinci rasta, što očigledno vrijedi i za Hrvatsku. Naime, s pojavom krize u Hrvatskoj dolazi do negativnih stopa rasta, tj. divergencije njezinog poslovnog ciklusa od poslovnih ciklusa zemalja eurozone.

6. ZAKLJUČNA RAZMATRANJA

Proces globalizacije i liberalizacije kapitalnih tokova potaknuo je snažno financijsko integriranje zemalja. Financijska integracija važna je zbog učinkovite alokacije resursa te učinkovite i glatke transmisije monetarne politike eurozone. Prema neoklasičnom modelu rasta financijska integracija potiče kretanje kapitala prema područjima s većom graničnom proizvodnošću kapitala, što u konačnici potiče veće stope rasta i postizanje realne konvergencije slabije razvijenih zemalja i razvijenijih zemalja. Međutim, rezultati istraživanja ukazuju na problem rasta temeljenog na stranoj štednji. Naime, snažni kapitalni priljevi iz zemalja eurozone u Hrvatskoj nisu usmjereni u produktivne investicije, nego većim dijelom u potrošnju. Na taj način onemogućena je realna konvergencija, a porastao je rizik od prezaduživanja.

Financijska integracija putem tržišnog mehanizma podjele rizika omogućava apsorpciju idiosinkratskih šokova koji su posebno problematični u valutnom području jer na njih nije moguće djelovati zajedničkom monetarnom politikom. Upravo je to ključna funkcija financijske integracije za zemlje valutnog područja jer na taj način omogućava njegovo funkcioniranje. S obzirom da na taj način ujedno smanjuje i troškove monetarnog integriranja, važna je i za zemlje koje su u procesu monetarnog integriranja poput Hrvatske. Međutim, pojava krize potvrdila je naivnost koncepta temeljenog na financijskoj integraciji, i potrebu njegove nadopune drugim mehanizmima apsorpcije šokova, prvenstveno anticikličkom fiskalnom politikom i fleksibilnim tržištem rada.

Uz financijsku integraciju teorija optimalnih valutnih područja istaknula je usklađenost poslovnih ciklusa kao sveobuhvatni (meta) kriterij monetarnog integriranja. Naime, zemlje s usklađenijim poslovnim ciklusima (poslovni ciklusi koji imaju isti tajming, smjer i magnitudu) imaju manje troškove napuštanja vlastite monetarne politike (koja zemljama predstavlja važni mehanizam stabilizacije) jer se u tom slučaju minimiziraju problemi neodgovarajuće monetarne politike (tzv. *one size fits all* problem).

Iako financijska integracija i usklađenost poslovnih ciklusa predstavljaju važne kriterije monetarnog integriranja (što indicira njihov pozitivan odnos), recentna teorijska literatura i empirijska istraživanja potvrđuju da njihov odnos nije jednoznačan. Stoga je bilo zanimljivo utvrditi kakav je utjecaj financijske integracije na usklađivanje poslovnih ciklusa, tj. kojim se kanalima navedeni utjecaj realizira. Navedeni problem u znanstvenoj i stručnoj literaturi još uvijek nije dovoljno istražen, a otvorena su mnoga pitanja na koja ne postoji jednoznačan odgovor. O važnosti navedene problematike govori i činjenica da je problem istraživanja ove disertacije u širem kontekstu dio *consumptions correlation puzzle* koja predstavlja jednu od šest najvećih puzli u međunarodnoj makroekonomiji.

Analiza utjecaja financijske integracije na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone važna je jer financijska integracija predstavlja jedan od ključnih kanala transmisije poslovnih ciklusa za malu otvorenu ekonomiju kao što je Hrvatska, i to posebice kad se promatra sa zemljama eurozone s kojima Hrvatska ostvaruje većinu svojih kapitalnih tokova. Iz navedene analize proizlaze implikacije za vođenje hrvatske makroekonomske politike u uvjetima snažnog priljeva kapitala. Također, analizom je omogućena bolja procjena troškova monetarnog integriranja Hrvatske sa zemljama eurozone te identifikacija nedostataka i ograničenja financijske integracije kao ključnog koncepta u arhitekturi valutnih područja.

Istraživanja ovog tipa koji obuhvaćaju Hrvatsku uključuju tek nekoliko radova koji uglavnom analiziraju presječne (engl. cross section) podatke čime je zanemarena vremenska dinamika. Dodatno, radovi većinom obuhvaćaju pretkrizno razdoblje, a ovom disertacijom vremenska dimenzija proširena je i na recentno razdoblje. Osim toga, za razliku od ostalih istraživanja koja uključuju sve parove zemalja u uzorku (čime se mogu izvući općeniti zaključci za skupinu zemalja), u ovoj disertaciji problem je sagledan iz perspektive Hrvatske što do sada nije napravljeno.

U skladu s teorijskim okvirom, u ovom istraživanju polazi se od pretpostavke da utjecaj financijske integracije na usklađivanje poslovnih ciklusa nije jednoznačan jer ovisi o utjecaju nekoliko transmisijskih kanala koji imaju suprotni smjer djelovanja. Zbog toga je u analizu utjecaja financijske integracije na usklađivanje poslovnih ciklusa, osim izravnog utjecaja putem

kreditnog i kapitalnog kanala (te kanala bilance i blagostanja), uključeno i djelovanje financijske integracije putem neizravnih kanala - sektorske specijalizacije i trgovinske integracije. Kanal specijalizacije ima važnu ulogu jer mijenja strukturu ekonomija i time povećava rizik od pojave idiosinkratskih šokova. Osim toga, određuje potencijal rasta ekonomije, tj. omogućava postizanje realne konvergencije ili pak potiče divergenciju ako se materijaliziraju negativni učinci specijalizacije. Dodatno, analiziran je utjecaj različitih oblika financijske integracije da bi se utvrdilo postoji li razlika u njihovom djelovanju na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone, tj. dominiraju li različiti transmisijski kanali kod različitih oblika kapitala kao što to teorija ističe.

U nastavku je prikazana rasprava o rezultatima istraživanja.

6.1. Rasprava o rezultatima istraživanja

Rezultati provedenog istraživanja potvrđuju ambivalentan odnos financijske integracije i usklađenosti poslovnih ciklusa. Naime, financijska integracija utječe na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone putem nekoliko izravnih i neizravnih kanala koji imaju suprotan smjer djelovanja. Identifikacija kanala u empirijskom modelu analizirana je formuliranjem tri istraživačke hipoteze koje su se dokazivale putem tri statička panela.

U panelu 1. (statički panel s fiksnim učinkom) analizirane su determinante usklađenosti poslovnih ciklusa iz teorije optimalnih valutnih područja (financijska integracija, trgovinska integracija, sličnost sektorskih struktura i konvergencija fiskalnih politika) s ciljem dokazivanja hipoteze H1 koja navodi da financijska integracija izravno pozitivno utječe na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone.

Rezultati panela potvrđuju pozitivan utjecaj trgovinske integracije na usklađivanje poslovnih ciklusa što znači da trgovinski tokovi između Hrvatske i zemalja eurozone putem generiranja potražnje (multiplikator vanjske trgovine) potiču usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone. Trgovinski tokovi sa zemljama eurozone predstavljaju važni kanal transmisije poslovnih ciklusa za malu, otvorenu ekonomiju kao što je Hrvatska. S obzirom na

strukturu hrvatskih trgovinskih tokova u kojoj dominira uvoz roba iz zemalja eurozone, očigledno je da se pad robnih tokova s navedenim zemljama u kriznom razdoblju negativno odrazio na hrvatski poslovni ciklus, tj. uzrokovao divergenciju poslovnog ciklusa Hrvatske i poslovnih ciklusa zemalja eurozone. To upućuje na različite modele rasta Hrvatske (rast temeljen na potrošnji – engl. demand driven) i razvijenih zemalja eurozone (rast temeljen na izvozu – engl. export led).

Predznak koeficijenta uz sličnost sektorskih struktura je teorijski očekivan, ali nije statistički značajan. Međutim, analiza robusnosti rezultata provedena korištenjem PCSE procjenitelja (koji uklanja problem autokorelacije i heteroskedastičnosti reziduala) pokazuje da postoji značajnost utjecaja na suženom vremenskom intervalu (2009.-2016.). Time se potvrđuje važnost kompozicije sektorskih struktura za usklađivanje poslovnih ciklusa zemalja. Naime, razlike u sektorskim strukturama Hrvatske i zemalja eurozone za vrijeme i nakon krize potaknule su asimetričnu transmisiju šokova koja je uzrokovala divergenciju njihovih poslovnih ciklusa te time povećala troškove monetarnog integriranja Hrvatske.

Dalje, rezultati panela potvrđuju da konvergencija fiskalnih politika potiče usklađivanje poslovnog ciklusa, tj. divergentne fiskalne politike uzrokuju divergenciju poslovnog ciklusa Hrvatske od poslovnih ciklusa zemalja eurozone. Iako bi fiskalna politiku trebala imati anticikličku stabilizacijsku ulogu, navedeno upućuje da je diskrecijska fiskalna politika (posebice hrvatska fiskalna politika) u promatranom razdoblju procikličkog karaktera. S obzirom na to da je za indikator fiskalne politike korišten strukturni deficit (koji je neovisan o poslovnom ciklusu), zaključak je da bi se Hrvatska i zemlje eurozone trebale pridržavati Pakta o stabilnosti i rastu. Osim što bi izbjegla stvaranje velikog deficita i javnog duga, na taj način Hrvatska bi smanjila rizik od pojave idiosinkratskih fiskalnih šokova koji povećavaju troškove njezinog monetarnog integriranja. Također, s obzirom da su fiskalne politike zemalja eurozone decentralizirane (u nadležnosti zemalja), potreban je zaokret u vođenju hrvatske fiskalne politike koji bi omogućio njezino anticikličko stabilizacijsko djelovanje. Na taj način djelovanjem fiskalne politike omogućila bi se apsorpcija idiosinkratskih šokova, a koja je posebno važna u situaciji gubitka vlastite monetarne politike (prilikom monetarnog integriranja) i nedjelotvornosti mehanizma privatne podjele rizika putem financijske integracije.

Rezultati panela 1. pokazuju da različiti oblici kapitala različito utječu na usklađivanje poslovnih ciklusa promatranih zemalja. U statičkom panelu s fiksnim učinkom, integracija tržišta kapitala (indikator bilateralne izravne strane investicije) negativno utječe na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone**.** Na općenitoj teorijskoj razini potvrđuje se djelovanje kanala blagostanja (objašnjenog u teoriji realnih poslovnih ciklusa) putem kojeg visoko mobilni kapital seli u područja s većim rastom čime potiče divergenciju poslovnih ciklusa. Naime, prije pojave krize (u razdoblju gospodarskog rasta) u Hrvatskoj dolazi do snažnijeg priljeva izravnih stranih investicija, a s pojavom krize (kada dolazi do kontrakcije hrvatskog poslovnog ciklusa) dolazi do njihovog zastoja.

Ključni izravni kanal utjecaja u kontekstu problema ovog istraživanja je kapitalni kanal koji putem ukriženog prava vlasništva na imovinu, kamatu i rentu smanjuje rizik od pojave idiosinkratskih šokova (*ex ante* osiguranje) i na taj potiče usklađivanje poslovnih ciklusa zemalja. Negativni predznak utjecaja u panelu pokazuje da kapitalni kanal predstavlja "pravi" oblik podjele rizika jer pokazuje da izravne strane investicije nisu izraženo procikličnog karaktera (s pojavom krize došlo je do divergencije poslovnog ciklusa Hrvatske i poslovnih ciklusa zemalja eurozone, ali nije došlo do snažnijeg odljeva izravnih stranih investicija) što je izrazito važno za podjelu rizika. Međutim, rezultati panela potvrđuju da kapitalni kanal, koji je važan u kontekstu monetarnog integriranja Hrvatske (i funkcioniranja valutnih područja), nije dovoljno snažan da omogući visoki stupanj *ex ante* osiguranja, tj. spriječi pojavu idiosinkratskih šokova. Iako je Hrvatska u pretkriznim godinama imala priljev izravnih stranih investicija na razini od otprilike 14 posto BDP-a, treba imati na umu da je ključ u ukriženom pravu vlasništva, dakle istovremeno bi trebale postojati intenzivnije izravne strane investicije iz Hrvatske u zemlje eurozone da bi osnovni uvjet podjele rizika bio zadovoljen. To upućuje na potrebu poticanja prekograničnog vlasničkog kapitala (u oba smjera) zbog jačanja kapitalnog kanala, a s ciljem veće apsorpcije idiosinkratskih šokova.

S druge strane, u statičkom panelu s fiksnim učinkom integracija tržišta kredita (indikator desetogodišnje državne obveznice) pozitivno utječe na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone. Rezultati na općenitoj teorijskoj razini potvrđuju djelovanje kanala bilance objašnjenog u literaturi o zarazi prema kojoj pojava financijskih šokova u jednoj zemlji uzrokuje

kontrakciju bilanci banaka/multinacionalnih poduzeća u drugoj zemlji i time potiče usklađivanje poslovnih ciklusa.

Osim toga, na integriranom tržištu kredita djeluje kreditni kanal koji je također vrlo važan za monetarno integriranje jer omogućava *ex post* prilagodbu na idiosinkratske šokove. Pozitivan utjecaj u panelu potvrđuje da je Hrvatska prije krize putem kreditnog kanala učinkovito apsorbirala idiosinkratske šokove što je potaknulo usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone. Međutim, s pojavom krize dolazi do dezintegracije kreditnog tržišta i posljedično pada usklađenosti poslovnog ciklusa Hrvatske sa zemljama eurozone, što potvrđuje neučinkovitost kreditnog kanala za vrijeme financijskih poremećaja i kriza. Naime, u takvoj situaciji dolazi do "pucanja" kreditnog kanala, tj. nemogućnosti da se *ex post* apsorbiraju idiosinkratski šokovi i na taj način uskladi hrvatski poslovni ciklus s poslovnim ciklusima zemalja eurozone. Neučinkovitost kreditnog kanala posljedica je procikličke prirode dugovnog kapitala, a predstavlja nepoželjnu pojavu jer otežava apsorpciju idiosinkratskih šokova kad je to najpotrebnije – kod kontrakcije poslovnog ciklusa.

Panelom 2. analiziran je neizravni utjecaj financijske integracije na usklađivanje poslovnog ciklusa putem kanala specijalizacije u svrhu dokazivanja hipoteze H2 koja navodi da financijska integracija putem specijalizacije neizravno negativno utječe na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone. Identifikacija navedenog kanala zahtijevala je potvrdu utjecaja financijske integracije na sektorske strukture promatranih zemalja te potvrdu utjecaja različitih sektorskih struktura na (ne)usklađivanje poslovnih ciklusa promatranih zemalja. Pozitivan utjecaj sličnosti sektorskih struktura na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone već je prethodno potvrđen statičkim panelom s fiksnim učinkom (panel 1.). Kod analize utjecaja financijske integracije na sektorske strukture promatranih zemalja, rezultati Studentovog t-testa pokazali su statistički značajnu razliku sličnosti sektorskih struktura u različitim razdobljima i potrebu analize na suženim vremenskim intervalima. Rezultati panela na suženim vremenskim intervalima potvrđuju da financijska integracija negativno utječe na sličnost sektorskih struktura Hrvatske i zemalja eurozone što ukazuje na specijalizaciju promatranih zemalja. Naime, snažni priljevi kapitala u Hrvatsku potaknuli su rast cijena i plaća, tj. realnu aprecijaciju efektivnog deviznog tečaja kune koja je uzrokovala pomicanje sektorske strukture Hrvatske prema

nerazmjenjivim sektorima. Specijalizacija hrvatske ekonomije prema nerazmjenjivim sektorima povećava osjetljivost na idiosinkratske šokove, tj. potiče divergenciju poslovnog ciklusa Hrvatske i zemalja eurozone. Osim toga, važno je naglasiti još jedan problem koji se javlja kod ovakvog oblika specijalizacije. Naime, literatura potvrđuje da su razmjenjivi sektori generator rasta ekonomije. U tom kontekstu, specijalizacija prema nerazmjenjivim sektorima smanjuje potencijal rasta hrvatske ekonomije tj. onemogućava njezinu realnu konvergenciju prema zemljama eurozone.

Ovdje se još jednom može uočiti važnost mehanizma tržišne podjele rizika. Naime, u pretkriznom razdoblju (koje obilježavaju snažni kreditni i kapitalni priljevi) specijalizacija nije uzrokovala divergenciju poslovnih ciklusa jer su putem kapitalnog i kreditnog kanala uspješno apsorbirani idiosinkratski šokovi. To potvrđuje i činjenica da razlika u sektorskim strukturama u tom razdoblju nije statistički značajno utjecala na usklađenost poslovnih ciklusa, tj. različite sektorske strukture Hrvatske i zemalja eurozone nisu uzrokovale divergenciju njihovih poslovnih ciklusa. S pojavom krize i slabljenjem mehanizma podjele rizika dolazi do izražaja važnost sličnih sektorskih struktura za usklađivanje poslovnih ciklusa.

Dodatno, panelom je potvrđen negativan utjecaj razlika u stupnju razvijenosti zemalja (Hrvatske i zemalja eurozone) na sličnost njihovih sektorskih struktura što pokazuje da je stupanj razvijenosti važna odrednica sektorskih struktura promatranih zemalja**.** S obzirom na to da stupanj razvijenosti implicira smjer kretanja kapitala, a kapitalni tokovi utječu na sektorske strukture zemalja, jasno je da bi stupanj razvijenosti trebao biti jedan od važnih kriterija monetarnog integriranja. Međutim, stupanj razvijenosti kao kriterij monetarnog integriranja neopravdano je zanemaren u teoriji optimalnih valutnih područja.

U trećoj istraživačkoj hipotezi analiziran je utjecaj financijske integracije na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone putem kanala trgovinske integracije. Rezultati panela potvrđuju pozitivan utjecaj financijske integracije na trgovinsku integraciju što indicira da kretanje kapitala potiče trgovinsku razmjenu promatranih zemalja. S obzirom na to da je prethodno potvrđen pozitivan utjecaj trgovinske integracije na usklađivanje poslovnih ciklusa promatranih zemlja, može se zaključiti da financijska integracija potiče usklađivanje poslovnih ciklusa Hrvatske sa zemljama eurozone putem kanala trgovinske integracije. Međutim, dobivene

rezultate potrebno je objasniti u kontekstu stvaranja makroekonomskih neravnoteža koje su posljedica snažnih kapitalnih priljeva.

Naime, snažni priljevi dugovnog kapitala u Hrvatskoj su generirali potražnju koja je potaknula snažnu robnu razmjenu Hrvatske sa zemljama eurozone. Međutim, rast temeljen na domaćoj potražnji uzrokovao je stvaranje vanjskih neravnoteža koje su se očitovale u visokom deficitu tekućeg računa hrvatske bilance plaćanja. Istodobno, razvijenije zemlje eurozone (zemlje jezgre) generirale su velike suficite. U konačnici je (s pojavom krize) prilagodba na vanjske neravnoteže postignuta drastičnim smanjenjem domaće potražnje što se odrazilo na pad outputa i zaposlenosti, tj. snažnoj kontrakciji hrvatskog poslovnog ciklusa.
Dakle, u pretkriznom razdoblju financijska integracija putem trgovinskih tokova potiče usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone, ali se usklađivanje realizira uz razvoj velikih makroekonomskih neravnoteža. Neravnoteže se ispravljaju nakon 2008. godine kada dolazi do pada trgovinskih tokova i divergencije poslovnog ciklusa Hrvatske od poslovnih ciklusa zemalja eurozone. Iz toga proizlazi da se model rasta Hrvatske razlikuje od modela rasta razvijenih zemalja eurozone. Različiti modeli rasta inherentno uzrokuju stvaranje makroekonomskih neravnoteža čiji ispravak uglavnom ide na teret zemalja s dugovnim modelom rasta (kao što je Hrvatska).

Konačno, pozitivan utjecaj financijske integracije na trgovinske tokove i analiza trgovinskih tokova u promatranom razdoblju indiciraju da glavni uzrok razvoja makroekonomskih neravnoteža (nestabilnosti) u Hrvatskoj nije pad konkurentnosti, već snažni rast domaće potražnje temeljen na obimnom priljevu dugovnog kapitala.

6.2. Doprinosi i implikacije rezultata istraživanja

Konceptualni okvir za promišljanje o koristima i troškovima monetarnog integriranja pruža teorija optimalnih valutnih područja. U ovoj disertaciji sistematizirani su i kritički analizirani kriteriji navedene teorije. Poseban naglasak stavljen je na financijsku integraciju, koja u postojećoj arhitekturi eurozone predstavlja temeljni stup, a osim toga neizbježan je proces koji karakterizira

modernu globalnu ekonomiju. Međutim, očigledno je da financijsko integriranje nosi sa sobom i određene nedostatke (i ograničenja) koji su u navedenoj teoriji podcijenjeni. Stoga kritička analiza kriterija teorije optimalnih valutnih područja, a posebice financijske integracije predstavlja teorijski doprinos ove disertacije.

Dalje, iako je financijska integracija (kao nužni preduvjet kretanja kapitala) ključna sa stajališta monetarnog integriranja i funkcioniranja valutnih područja, njezin utjecaj na usklađivanje poslovnih ciklusa zemalja nedovoljno je istražen u inozemnoj, a posebice u domaćoj znanstvenoj i stručnoj literaturi. U tom kontekstu ova disertacija daje doprinos u teorijskom i aplikativnom smislu.

Teorijski doprinos očituje se u kritičkom promišljanju i analizi konceptualne snage teorije optimalnih valutnih područja. Naime, navedena teorija precijenila je mogućnosti financijske integracije kao tržišnog mehanizma apsorpcije idiosinkratskih šokova jer je kapitalni kanal nedovoljno snažan, a kreditni kanal neučinkovit za vrijeme financijskih poremećaja i kriza. Osim toga, teorija je zanemarila mogućnost pojave makroekonomskih neravnoteža koje djelomično proizlaze iz negativnih učinaka financijske integracije.

Dalje, teorijski doprinos istraživanja vidljiv je u sistematizaciji teorijskih i empirijskih spoznaja o utjecaju financijske integracije na usklađivanje poslovnih ciklusa na temelju kojih je izrađen empirijski model za utvrđivanje zakonitosti, smjera i intenziteta utjecaja financijske integracije na usklađivanje poslovnih ciklusa. U tom kontekstu, identificirani su izravni i neizravni transmisijski kanala utjecaja financijske integracije koji doprinose boljem shvaćanju ovog kompleksnog odnosa.

Također, doprinos se očituje u korištenju unaprijeđene metodologije mjerenja usklađenosti poslovnih ciklusa uzimajući u obzir ograničenja dosadašnjih istraživanja. U ovoj disertaciji detaljno je analizirana metodologija mjerenja usklađenosti poslovnih ciklusa. Korištenjem realnog bruto domaćeg proizvoda uklonjeni su nedostaci koji proizlaze iz nedovoljne sveobuhvatnosti (indeks industrijske proizvodnje) ili nedovoljne preciznosti (stopa nezaposlenosti) agregatne ekonomske aktivnosti zemalja; korištenjem metode proizvodne funkcije uklonjeni su nedostaci procjene poslovnih ciklusa putem univarijatnih filtara; a korištenjem Cerqueira-Martinsovog

korelacijskog indeksa dinamizirana je mjera usklađenosti poslovnih ciklusa i uklonjeni su nedostaci korištenja Pearsonovog koeficijenta korelacije (zanemarivanje amplitudne razlike) i pomičnog vremenskog okvira (značajni gubitak broja opažanja i problem autokorelacije u panelima).

Na temelju kreiranog empirijskog modela i korištenjem unaprijeđene metodologije mjerenja usklađenosti poslovnih ciklusa utvrđen je smjer i intenzitet utjecaja financijske integracije na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone te analiziran suodnos financijske integracije s trgovinskom integracijom i sličnošću sektorskih struktura kao važnim determinantama usklađenosti poslovnih ciklusa, što predstavlja doprinos mjerenju budući ne postoje istraživanja ovakvog tipa za Hrvatsku.

Analiza utjecaja financijske integracije na usklađivanje poslovnih ciklusa Hrvatske sa zemljama eurozone ima važne implikacije za provođenje hrvatske makroekonomske politike, kao i za uvođenje eura u Hrvatsku. Rezultati istraživanja potvrđuju da kapitalni tokovi imaju važnu ulogu u transmisiji poslovnih ciklusa zemalja eurozone u Hrvatsku te ih svakako treba uzeti u obzir prilikom kreiranja hrvatske makroekonomske politike.
S obzirom na to da proces financijskog integriranja Hrvatske nije moguće zaustaviti (a očigledno je da snažni priljev dužničkog kapitala ima negativne učinke) potrebno je provoditi kvalitetne makroprudencijalne mjere s ciljem očuvanja stabilnosti financijskog sustava i sprječavanja stvaranja makroekonomskih neravnoteža.

Dalje, rezultati istraživanja pokazuju da je kod financijskog integriranja zemalja, osim obujma kapitalnih tokova vrlo važna i njihova struktura u kojoj je poželjan veći udio izravnih stranih investicija zbog manje procikličnosti i većeg kapaciteta podjele rizika.

Konačno, rezultati istraživanja potvrđuju da financijska integracija ne omogućava dovoljno snažnu apsorpciju idiosinkratskih šokova u Hrvatskoj. To je posebno izraženo u situaciji naglog zastoja kapitalnih priljeva jer tada dolazi do pucanja kreditnog kanala. Stoga je potrebno da osim financijske integracije postoje i drugi mehanizami apsorpcije idiosiknkratskih šokova poput anticikličke fiskalne politike i fleksibilnosti tržišta rada. Ako takvi mehanizmi ne postoje, u

Hrvatskoj će se pojaviti problemi kod provođenja zajedničke monetarne politike eurozone, tj. značajno rastu njezini troškovi prihvaćanja eura.

Osim toga, zaustavljanje procesa specijalizacije, koja u Hrvatskoj pod utjecajem kapitalnih priljeva ide prema nerazmjenjivim sektorima, moguće je postići snažnijim priljevom vlasničkog kapitala u razmjenjivi sektor. Na taj način djelomično će se riješiti i problem postizanja realne konvergencije koja je neophodna za dugoročnu stabilnost i opstanak valutnog područja. Navedeno predstavlja aplikativni doprinos ovog istraživanja.

6.3. Ograničenja istraživanja

Istraživanje provedeno u ovoj disertaciji ima nekoliko ograničenja koja su istaknuta u nastavku.

Mjerenje stupnja financijske integracije poprilično je zahtjevno jer bi prava mjera financijske integracije trebala biti sveobuhvatna – uzeti u obzir sve oblike kapitala. U istraživanjima ovakvog tipa najčešće se koriste cjenovno i/ili količinski orijentirane mjere financijske integracije, a navedene mjere imaju određena ograničenja. U ovom istraživanju korištene su obje mjere: (i) količinski orijentirana mjera u kojoj su za indikator financijske integracije korištene bilateralne izravne strane investicije; i (ii) cjenovno orijentirana mjera u kojoj je za indikator financijske integracije korištena realna stopa povrata na desetogodišnje obveznice.

U ovom istraživanju za količinski orijentiranu mjeru financijske integracije korištene su izravne strane investicije koje nisu najveći oblik kapitalnih tokova između Hrvatske i zemalja eurozone. Naime, iz mjere financijske integracije izostavljena su portfeljna ulaganja i ostala ulaganja jer za njih podaci na bilateralnoj razini (između Hrvatske i zemalja eurozone) postoje tek za nekoliko recentnih godina, a to nije dovoljno za njihovo uključivanje u navedenu mjeru. Isključivanjem portfeljnih i ostalih ulaganja djelomično se gubi na sveobuhvatnosti mjere financijske integracije. Osim toga, kretanje kapitala između zemalja ne mora nužno značiti da su financijska tržišta integrirana, međutim to je općenito ograničenje na razini količinski orijentiranih mjera financijske integracije.

Kod korištenja cjenovno orijentiranih mjera trebalo bi uključiti razliku povrata (razliku u cijeni) i na ostalim financijskim tržištima, a ne samo tržište desetogodišnjih državnih obveznica. To bi podrazumijevalo konstruiranje bilateralnih kompozitnih indikatora, što je izrazito kompleksna zadaća koja nadilazi okvir ove disertacije. Dodatno, s obzirom na to da za Hrvatsku ne postoje podaci o realnim stopama povrata na desetogodišnje obveznice za nekoliko godina na početku vremenske serije (jer nisu postojale desetogodišnje državne obveznice) one su procijenjene, što automatski nameće ograničenja vezana uz metodologiju izračuna.

Dalje, iako bi sveobuhvatna mjera trgovinske integracije trebala obuhvatiti razmjenu roba i usluga, za indikator trgovinske integracije korištena je isključivo bilateralna robna razmjena Hrvatske sa zemljama eurozone. Naime, podaci o bilateralnoj razmjeni usluga Hrvatske sa zemljama eurozone dostupni su za tek nekoliko recentnih godina (i za manji broj zemalja eurozone), stoga bilateralna trgovina uslugama nije uključena prilikom izračuna trgovinske integracije. S obzirom na to da robni tokovi iznose dvije trećine ukupnih realnih tokova, očigledno je da ovako konstruirana mjera trgovinske integracije ima ograničenje u vidu sveobuhvatnosti ukupnih realnih tokova (u zamjenu za preciznost koja proizlazi iz korištenja bilateralnih robnih tokova).

Treće, postoje određena ograničenja kod mjerenja usklađenosti poslovnih ciklusa. Naime, prilikom analize za indikator agregatne ekonomske aktivnosti korišten je realni bruto domaći proizvod koji je dostupan na tromjesečnoj frekvenciji (što je njegov najveći nedostatak u odnosu na indeks industrijske proizvodnje ili stopu nezaposlenosti koji su dostupni na mjesečnoj frekvenciji). Međutim, zbog potrebe usklađivanja s frekvencijama ostalih indikatora korištenih u empirijskom modelu, u istraživanju je korišten realni BDP na godišnjoj frekvenciji čime se dodatno smanjuje broj opažanja i onemogućava preciznija (kvalitetnija) analiza dinamike poslovnih ciklusa zemalja, a time i usklađenosti poslovnog ciklusa Hrvatske s poslovnim ciklusima zemalja eurozone. Osim toga, usklađenost poslovnih ciklusa mjeri se Cerqueira-Martinsovim (2009) indeksom koji je asimetričan i vrijednosti su mu ograničene unutar intervala (maksimalna gornja vrijednost je 1) što može stvoriti problem u vidu zadržavanja procijenjenih vrijednosti unutar granica.

Četvrto, u empirijski model utjecaja financijske integracije na usklađivanje poslovnih ciklusa nije uključena fleksibilnost tržišta rada koja ima važnu ulogu tržišnog mehanizama stabilizacije gospodarstva (uglađivanja poslovnih ciklusa) i zasigurno značajno utječe na dinamiku poslovnih ciklusa zemalja. Glavni razlog isključivanja navedene varijable iz empirijskog modela je nedostupnost podataka. Na taj način model utjecaja djelomično gubi na kvaliteti.

Dalje, istraživanje je provedeno na uzorku Hrvatske i 19 zemalja eurozone, pri čemu su sve varijable koje se koriste u modelu konstruirane u bilateralnom obliku - jedno opažanje uključuje međuodnos Hrvatske i odabrane zemlje eurozone u promatranoj godini. Navedenom metodologijom u središte interesa stavlja se Hrvatska što omogućava donošenje zaključaka i važne implikacije izravno za Hrvatsku. Međutim, ograničenje ovog istraživanja je znatno manji broj opažanja u uzorku (za razliku od sličnih istraživanja koja promatraju sve moguće parove zemalja u uzorku). Stoga se istraživanje temelji na pretpostavci da zemlje eurozone čine homogeni skup zemalja. Iako imaju zajedničku valutu (dakle zadovoljile su nominalne kriterije konvergencije po pitanju stabilnosti cijena, kamatnih stopa i održivosti javnih financija) i brojne druge sličnosti koje proizlaze iz članstva u međunarodnoj zajednici, zemlje eurozone ipak su djelomično različite. To potvrđuje i dio istraživanja koji razdvaja dvije skupine zemalja u eurozoni: jezgru i rubne zemlje. U tom kontekstu, određena ograničenja proizlaze iz djelomično heterogenog uzorka. Nažalost, podjela zemalja eurozone u dvije skupine prepolovila bi ionako smanjeni broj opažanja, čime bi se ugrozila kvaliteta ekonometrijske analize.

Konačno, struktura uzorka sužava mogućnost izbora procjenitelja parametara modela. Konkretno, velika vremenska dimenzija u odnosu na prostornu isključuje mogućnost korištenja dinamičkog panela (GMM - Arellano Bond) koji ima prednosti kod korištenja u modelima s endogenim varijablama u odnosu na korišteni statički panel s fiksnim učinkom.

6.4. Smjernice za buduća istraživanja

Iz prethodno navedenih ograničenja istraživanja proizlaze i smjernice za buduća istraživanja. S obzirom na to da recentna vremenska razdoblja uključuju obuhvatniju statistiku, u bliskoj

budućnosti bit će omogućeno kvalitetnije mjerenje trgovinske integracije koje uključuje bilateralnu razmjenu usluga Hrvatske sa zemljama eurozone. Također, kroz nekoliko godina će se stvoriti dovoljno velika vremenska serija koja će omogućiti uključivanje bilateralnih portfeljnih ulaganja i ostalih ulaganja kod mjerenja financijske integracije što će zasigurno pridonijeti kvaliteti istraživanja.

Drugo, jedna od smjernica za buduća istraživanja je transformacija Cerqueira-Martinsovog (2009) indeksa (mjere usklađenosti poslovnih ciklusa) s ciljem uklanjanja njegove asimetričnosti.

Dalje, već je naglašeno da je teorija optimalnih valutnih područja istaknula važnost fleksibilnosti cijena i plaća te mobilnosti rada kao važnih mehanizama prilagodbe kod pojave makroekonomskih poremećaja. Uključivanje navedenih varijabli u model zasigurno bi poboljšalo njegovu kvalitetu (smanjilo problem izostavljenih varijabli) i omogućilo bolju kvantifikaciju utjecaja financijske integracije na usklađivanje poslovnih ciklusa promatranih zemalja.

Zbog već naglašenog problema heterogenosti zemalja eurozone, bilo bi zanimljivo vidjeti kakav je utjecaj financijske integracije na usklađivanje poslovnog ciklusa Hrvatske sa zemljama jezgre eurozone (Njemačka, Francuska, Italija, Austrija, Belgija i Nizozemska), te postoji li razlika kad se Hrvatska promatra sa zemljama jezgre eurozone i kad se promatra sa rubnim zemljama eurozone. Dodatno, kad podaci postanu dostupni, bilo bi zanimljivo vidjeti postoji li razlika između utjecaja različitih oblika kapitalnih tokova (izravna strana ulaganja, portfeljna ulaganja i ostala ulaganja) na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone (ili jezgre/rubnih zemalja).

Konačno, s obzirom na važnost tržišnog mehanizma podjele rizika u valutnim područjima i zemljama koje su u procesu preuzimanja eura (poput Hrvatske), bilo bi zanimljivo istražiti koliki se udio idiosinkratskih šokova koji pogađaju Hrvatsku može apsorbirati putem kreditnog i kapitalnog kanala; te mijenja li se snaga apsorpcije putem navedenih kanala s obzirom na neke vanjske čimbenike.

LITERATURA

1. Abbott, A., Easaw, J. and Xing, T. (2008). Trade integration and business cycle convergence: is the relation robust across time and space? *The Scandinavian Journal of Economics*, 110(2), 403-417.

2. Abiad, A., Leigh, D. and Mody, A. (2007). International Finance and Income Convergence: Europe is Different. IMF Working Papers 07/64. *International Monetary Fund*. Dostupno na: http://www.imf.org/external/pubs/cat/longres.aspx?sk=20522 [pristupljeno: 13.06.2018.].

3. Acemoglu, D. and Zilibotti, F. (1997). Was Prometheus Unbound by Chance? Risk, Diversification and Growth. *The Journal of Political Economy*, 105(4), 709-751.

4. Adam, K., Jappelli, T., Padula, M. and Pagano, M. (2002). *Analyse, Compare, and Apply Alternative Indicators and Monitoring Methodologies to Measure the Evolution of Capital Market Integration in the European Union.* CSEF, Department of Economics and Statistics, University of Salerno. Dostupno na: https://www.researchgate.net/publication/237415991_Analyse_Compare_and_Apply_Alternative_Indicators_and_Monitoring_Methodologies_to_Measure_the_Evolution_of_Capital_Market_Integration_in_the_European_Union [pristupljeno:13.06.2018.].

5. Afonso, A. and Furceri, D. (2008). EMU enlargement, stabilization costs and insurance mechanisms. *Journal of International Money and Finance*, 27, 169-187.

6. Agénor, P. R. (2003). Benefits and costs of international financial integration: theory and facts. *The World Economy*, 26(8), 1089-1118.

7. Aizenman, J. and Noy, I. (2009). Endogenous Financial and Trade Openness. *Review of Development Economics*, 13(2), 175-189.

8. Akın, C. (2012). *Multiple determinants of business cycle synchronization*. Dostupno na: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=1022648 [pristupljeno:13.06.2018.].

9. Alesina, A., Barro, R. and Tenreyro, S. (2002). Optimal Currency Areas. *NBER Macroeconomics Annual*, 17, 301-356.

10. Alimi, N. (2015). The effect of trade, specialization and financial integration on business cycles synchronization in some mediterranean countries. *Asian Economic and Financial Review*, 5(1), 110-118.

11. Allen, F. and Gale, D. (2000). Financial contagion. *Journal of political economy*, 108(1), 1-33.

12. Aljinović, Z., Ercegovac, R. and Marasović, B. (2010). Country Risk Premium Development – Case Study Croatia. *International Conference on Education and Management Technology ICEMT 2010*. Dostupno na: https://ieeexplore.ieee.org/document/5657682 [pristupljeno: 13.06.2018.].

13. Altavilla, C. (2004). Do EMU members share the same business cycle? *Journal of Common Market Studies*, 42(5), 869–896.

14. Angeloni, I. and Dedola, L. (1999). From the ERM to the Euro: New Evidence on Economic and Policy Convergence among EU Countries. ECB Working Paper No. 4. *European Central Bank*. Dostupno na: https://www.ecb.europa.eu//pub/pdf/scpwps/ecbwp004.pdf [pristupljeno: 13.06.2018.].

15. Antonakakis, N. and Tondl, G. (2014). Does integration and policy coordination promote business cycle synchronization in the EU? *Emipirica*, 41(3), 541-575.

16. Arčabić, V. (2011). Usklađenost poslovnih ciklusa Republike Hrvatske sa zemljama Europske Unije. *Zbornik Ekonomskog fakulteta u Zagrebu*, 9(1), 127-144.

17. Arčabić, V. (2018). Hrvatska na putu u Eurozonu: analiza poslovnih ciklusa. In: Družić, G. and Družić, I. (Eds), *Zbornik radova znanstvenog skupa: Modeli razvoja hrvatskog gospodarstva*, Zagreb: Ekonomski fakultet, 157-176.

18. Arpaia, A., Kiss, A., Palvolgyi, B. and Turrini, A. (2016). Labour mobility and labour market adjustment in the EU. *IZA Journal of Migration*, 5(1), 5-21.

19. Artis, M., Chouliarakis, G. and Harischandra, P. K. G. (2011). Business cycle synchronization since 1880. *The Manchester School*, 79(2), 173-207.

20. Artis, M., Fidrmuc, J. and Scharler, J. (2008). The transmission of business cycles Implications for EMU enlargement. *Economics of Transition*, 16(3), 559-582.

21. Artis, M., Marcellino, M. and Proietti, T. (2003). Dating the European Business Cycle. CEPR Discussion Paper No. 3696. *Centre for Economic Policy Research*. Dostupno na: https://ssrn.com/abstract=374505 [pristupljeno: 13.06.2018.].

22. Artis, M. and Okubo, T. (2011). Does International Trade Really Lead to Business Cycle Synchronization? A panel data approach. *The Manchester School*, 79(2), 318-332.

23. Artis, M. and Zhang, W. (1999). Further evidence on the international business cycle and the ERM: is there a European business cycle? *Oxford Economic Papers*, 51(1), 120-132.

24. Asdrubali, P., Sorensen, B. E. and Yosha, O. (1996). Channels of Interstate Risk Sharing: United States 1963-1990. *The Quarterly Journal of Economics*, 111(4), 1081-1110.

25. Asteriou, D. and Moudatsou, A. (2015). Business Cycle Synchronization in the Enlarged EU: The Role of Bilateral Trade and FDI. *Review of Development Economics*, 19(1), 196–207.

26. Backus, D., Kehoe, P. and Kydland, F. (1992). International Real Business Cycles. *Journal of Political Economy*, 100(4), 745-775.

27. Baele, L., Ferrando, A., Hordahl P., Krylova, E. and Monnet, C. (2004). Measuring financial integration in the euro area. ECB Occasional paper series No. 14. *European Central Bank*. Dostupno na: https://www.ecb.europa.eu/pub/pdf/scpops/ecbocp14.pdf [pristupljeno: 13.06.2018.].

28. Baltzer, M., Cappiello, L., De Santis, R. and Manganelli, S. (2008). Measuring financial integration in new EU member states. ECB Occasional paper series No 81. *European Central Bank*. Dostupno na: https://www.ecb.europa.eu/pub/pdf/scpops/ecbocp81.pdf [pristupljeno: 13.06.2018.].

29. Basile, R. and Girardi, A. (2010). Specialization and risk sharing in European regions. *Journal of Economic Geography*, 10(5), 645-659.

30. Basu, A. and Srinivasan, K. (2002). Foreign Direct Investment in Africa: Some Case Studies. IMF Working Paper WP/02/61. *International Monetary Fund*. Dostupno na: https://www.imf.org/external/pubs/ft/wp/2002/wp0261.pdf [pristupljeno: 13.06.2018.].

31. Baxter, M. and Crucini, M. (1995). Business Cycles and the Asset Structure of Foreign Trade. *International Economic Review*, 36(4), 821-854.

32. Baxter, M. and King, R. G. (1999). Measuring business cycles: approximate band-pass filters for economic time series. *Review of economics and statistics*, 81(4), 575-593.

33. Baxter, M. and Kouparitsas, M. (2005). Determinants of business cycle comovement: a robust analysis. *Journal of Monetary Economics*, 52, 113–157.

34. Beck, N. and Katz, J. N. (1995). What to do (and not to do) with time-series cross-section data. *American Political Science Review*, 89, 634-647.

35. Beine, M., Candelon, B. and Hecq, A. (2000). Assessing a perfect European optimum currency area: a common cycles approach. *Empirica*, 27(2), 115-132.

36. Belke, A., Domnick, C. and Gros, D. (2017). Business Cycle Synchronization in the EMU: Core vs. Periphery. *Open Economies Review*, 28, 863–892.

37. Belullo, A., Šonje, V. i Vrbanc, I. (2000). *Je li Srednja Europa optimalno valutno područje?* HNB Istraživanja I- 8. Hrvatska narodna banka. Dostupno na: https://www.hnb.hr/documents/20182/121612/i-008.pdf/943e1e0d-5807-48c0-8c56-ecdb820942ab [pristupljeno: 13.06.2018.].

38. Benigno, G. and Fornaro, L. (2014). The Financial Resource Curse. *The Scandinavian Journal of Economics,* 116(1), 58–86.

39. Bergman, U. (2006). *Are European Business Cycles Converging?* Research Paper. Department of Economics, University of Copenhagen. Dostupno na: https://www.researchgate.net/profile/U_Bergman/publication/255648206_Are_European_Business_Cycles_Converging/links/543819b40cf2d6698bdd5fbf.pdf [pristupljeno: 13.06.2018.].

40. Bonfiglioli, A. (2008). Financial Integration, Productivity and Capital Accumulation. *Journal of International Economics,* 76, 337-355.

41. Boone, L. and Maurel, M. (1999). An Optimal Currency Area Perspective of the EU Enlargement to the CEECS. CEPR Discussion Paper No. 2119. *Centre for Economic Policy Research*. Dostupno na: http://www.cepr.org/active/publications/discussion_papers/dp.php?dpno=2119 [pristupljeno: 13.06.2018.].

42. Borio, C., Kharroubi, E., Upper, C. and Zampolli, F. (2015). Labour Reallocation and Productivity Dynamics: Financial Causes, Real Consequences. BIS Working Papers No 534. *Bank for International Settlements*. Dostupno na: https://www.bis.org/publ/work534.pdf [pristupljeno 13.06.2018.].

43. Boschan, C. and Ebanks, W. (1978). The Phase Average Trend: A New Way of Measuring Economic Growth. Proceedings of the Business and Economics Statistics Section. *American Statistical Association.*

44. Botrić, V., and Broz, T. (2016). Industry-specific Trade Patterns with Eurozone and Economic Crisis: Bosnia and Herzegovina, Croatia and Serbia. *Zbornik radova Ekonomskog fakulteta Sveučilišta u Mostaru*, 22, 7-25. Dostupno na: https://hrcak.srce.hr/203897 [Pristupljeno: 13.06.2018.]

45. Bower, U. and Guillemineau, C. (2006). Determinants of business cycle synchronisation across euro area countries. ECB Working Paper Series No. 587. *European Central Bank*. Dostupno na: http://www4.fe.uc.pt/jasa/m_i_2010_2011/determinants_business_cycle_synchronisation_across_euro_area_countries.pdf [pristupljeno 13.06.2018.].

46. Boyd, J. H. and Smith, B. D. (1992). Intermediation and the Equilibrium Allocation of Investment Capital: Implications for Economic Development. *Journal of Monetary Economics,* 30, 409-432.

47. Bry, G. and C. Boschan (1971). *Cyclical Analysis of Time Series: Selected Procedures and Computer Programs*. New York: National Bureau of Economic Research.

48. Buiter, W. (1995). Macroeconomic Policy During a Transition to Monetary Union. CEPR Discussion Paper No. 1222. *Centre for Economic Policy Research*. Dostupno na: https://ssrn.com/abstract=289491 [pristupljeno 13.06.2018.].

49. Bukovšak, M., Lukinić Čardić, G. and Ranilović, N. (2017). Structure of Capital Flows and Exchange Rate: The Case of Croatia. HNB Working Papers W-52. *Hrvatska narodna banka*. Dostupno na: https://www.hnb.hr/documents/20182/2030174/w-052.pdf/23163f57-2b6f-4f39-81b9-014c4304892b [pristupljeno 13.06.2018.].

50. Burns, A. E. and Mitchell, W.C. (1946). *Measuring Business Cycles*. New York: National Bureau of Economic Research.

51. Calderon, C., Chong, A. and Stein, E. (2007). Trade intensity and business cycle synchronization: Are developing countries any different? *Journal of International Economics,* 71, 2–21.

52. Calvo G., and Mendoza, E. (2000). Rational Contagion and the Globalization in Securities Markets. *Journal of International Economics*, 51(1), 79–119.

53. Camacho, M., Perez-Quiros, G. and Saiz, L. (2006). Are European Business Cycles Close Enough To Be Just One? *Journal of Economics Dynamics and Control,* 30, 1687–1706.

54. Caporale, G. and Girardi, A. (2016). Business Cycles, International Trade and Capital Flows: Evidence from Latin America. *Empirical Economics*, 50(2), 231-252.

55. Cecchetti, S. and Kharroubi, E. (2012). Reassessing the impact of finance on growth. BIS Working Papers No 381. Bank for International Settlements. Dostupno na: https://www.bis.org/publ/work381.pdf [pristupljeno 13.06.2018.].

56. Cerqueira, P. A. and Martins, R. (2009). Measuring the determinants of business cycle synchronization using a panel approach. *Economics Letters*, 102(2), 106-108.

57. Chinn, M. D. and Ito, H. (2008). A New Measure of Financial Openness. *Journal of Comparative Policy Analysis: Research and Practice,* 10(3), 309-322.

58. Christiano, L. J. and Fitzgerald, T. J. (2003). The band pass filter. *International economic review*, 44(2), 435-465.

59. Cimadomo, J., Hauptmeier, S., Palazzo, A. and Popov, A. (2018). Risk sharing in the euro area. ECB Economic Bulletin, Issue 3. *European Central Bank*. Dostupno na: https://www.ecb.europa.eu/pub/pdf/other/ecb.ebart201803_03.en.pdf: [pristupljeno 13.06.2018.].

60. Clarida, R., Gali, J. and Gertler, M. (1999). The science of monetary policy: A new keynesian perspective. *Journal of Economic Literature*, 37, 1661–1707.

61. Clark, T. E. and Wincoop, E. (2001). Borders and business cycles. *Journal of international Economics*, 55(1), 59-85.

62. Corbae, D. and Ouliaris, S. (2006). Extracting Cycles from Nonstationary Data. In: Corbae, D., Durlauf, S. and Hansen, B. (Eds.), *Econometric Theory and Practice: Frontiers of Analysis and Applied Research*, New York: Cambridge University Press.

63. Corden, W. M. (1972). *Monetary integration*. Essays in international finance, 93, international Finance Section, Princeton University.

64. Croux, C., Forni, M. and Reichlin, L. (2001). A measure of comovement for economic variables: Theory and empirics. *Review of Economics and Statistics*, 83(2), 232-241.

65. Dabrowski, M. (2002). Is there a room for national monetary policy in the era of globalization? Center for Social and Economic Research. Dostupno na: https://www.researchgate.net/publication/320868502_Is_there_a_room_for_national_monetary_policy_in_the_era_of_globalization/link/5a001e01aca272347a2b2aed/download [pristupljeno 13.06.2018.].

66. Darvas, Z., Rose, A. K. and Szapáry, G. (2007). Fiscal divergence and business cycle synchronization: irresponsibility is idiosyncratic. NBER Working paper 11580. *National Bureau of Economic Research*. Dostupno na: https://www.nber.org/papers/w11580.pdf [pristupljeno 13.06.2018.].

67. Darvas, Z. and Szapary, G. (2006). Business Cycle Synchronization in the Enlarged EU. *Open Economies Review*, 19(1), 1-19.

68. Davis, J. S. (2014). Financial integration and international business cycle co-movement. *Journal of Monetary Economics*, 64, 99-111.

69. Davis, J. S. (2015). The macroeconomic effects of debt- and equity-based capital inflows. *Journal of Macroeconomics*, 46(C), 81-95.

70. Dees, S. and Zorell, N. (2012). Business Cycle Synchronisation: Disentangling Trade and Financial Linkages. *Open Economies Review*, 23, 623-643.

71. De Grauwe, P. and Ji, Y. (2016). Flexibility Versus Stability: A Difficult Tradeoff in the Eurozone. *Credit and Capital Markets*, 49(3), 375-413**.**

72. De Grauwe, P. and Mongelli, F. P. (2005). Endogeneities of optimum currency areas: what brings countries sharing a single currency closer together? ECB Working Paper Series No. 468. *European Central Bank*. Dostupno na: https://www.ecb.europa.eu/pub/pdf/scpwps/ecbwp468.pdf?29304b3978d4e29741b276bce4430688G [pristupljeno 13.06.2018.].

73. De Grauwe, P. (2018). *Economics of Monetary Union*. 12 izdanje. Oxford: Oxford University Press.

74. De Haan, J., Inklaar, R. and Jong-A-Pin, R. (2008). Will business cycles in the Euro area converge? A critical survey of empirical research. *Journal of Economic Surveys* 22(2), 234–273.

75. Dellas, H. and Tavlas, G. (2009). An optimum-currency-area odyssey. *Journal of International Money and Finance*, 28, 1117–1137.

76. Derado, D. (2006). The effects of trade liberalisation among the South Eastern European countries. *Tourism and hospitality management*, 12(1), 1-17. Dostupno na: https://hrcak.srce.hr/61599 [Pristupljeno: 13.06.2018.]

77. Devenow, A. and Welch, I. (1996). Rational herding in financial economics. *European Economic Review*, 40(3-5), 603–615.

78. Dias, D., Marques, C. and Richmond, C. (2016). Misallocation and Productivity in the Lead Up to the Eurozone Crisis. *Journal of Macroeconomics*, 49, 46-70.

79. Dornbusch, R., Park, Y. C. and Claessens, S. (2000). Contagion: Understanding How It Spreads. *The World Bank Research Observer*, 15(2), 177–197.

80. Duran, H. and Ferreira-Lopes, A. (2017). Determinants of co-movement and of lead and lag behavior of business cycles in the Eurozone. *International Review of Applied Economics*, 31(2), 255-282.

81. Ederer, S. (2015). Macroeconomic Imbalances and Institutional Reforms in the EMU. Working Paper no 87. *Austrian Institute of Economic Research*. Dostupno na: https://www.wifo.ac.at/jart/prj3/wifo/resources/person_dokument/person_dokument.jart?publikationsid=57896&mime_type=application/pdf [pristupljeno 13.06.2018.].

82. Eichengreen, B. (1993). European monetary unification. *Journal of Economic Literature*, 31(3), 1321–1357.

83. Eichengreen, B. (1996). *Globalizing Capital: a History of the International Monetary System.* Princeton: Princeton University Press.

84. Eichengreen, B. (2001). Capital Account Liberalization: What do Cross-Country Studies Tell Us? *The World Bank Economic Review,* 15, 341-365.

85. EU Commission (1999). The Competition of European Industry. Working document of the services of the European Commission. *Directorate General Enterprise of the European Commission*. Dostupno na: http://ec.europa.eu/DocsRoom/documents/2980/attachments/1/translations/en/renditions/pdf [pristupljeno 13.06.2018.].

86. Europska Komisija (2015). Izvješće za Hrvatsku 2015. S detaljnim preispitivanjem o sprječavanju i ispravljanju makroekonomskih neravnoteža. Radni dokument službi komisije SWD(2015) 30 final. *Europska komisija*. Dostupno na: https://publications.europa.eu/en/publication-detail/-/publication/308d43cb-bdb2-11e4-bbe1-01aa75ed71a1/language-hr [pristupljeno 13.06.2018.].

87. Fenney, J. (1999). International risk sharing, learning by doing, and growth. *Journal of Development Economics,* 58, 297–318.

88. Fernandez-Arias, E. and Montiel, P. J. (1996). The Surge in Capital Inflows to Developing Countries: An Analytical Overview. *World Bank Economic Review,* 10(1), 51–77.

89. Fidrmuc, J. and Korhonen, I. (2006). Meta-Analysis of Business Cycle Correlations between the euro area and CEEC's. *Journal of Comarative Economics,* 34, 518-537.

90. Fleming, J. M. (1971). On exchange rate unification. *The Economic Journal,* 81(323), 467-488.

91. Fonseca, R., Patureau, L. and Sopraseuth, T. (2010). Business Cycle Comovement and Labor Market Institutions: An Empirical Investigation. *Review of International Economics,* 18(5), 865–881.

92. Frankel, J. A, and Rose, A. (1998). The Endogeneity of the Optimum Currency Area Criteria. *The Economic Journal,* 108, 1009-1025.

93. Frankel, J. and Rose, A. (2002). An Estimate of the Effect of Common Currencies on Trade and Income. *The Quarterly Journal of Economics,*117(2), 437-466.

94. Friedman, M. (1953). *Essays in Positive Economics*. Chicago: University of Chicago Press.

95. Furceri, D. and Karras, G. (2006). Are the new EU members ready for the EURO?A comparison of costs and benefits. *Journal of Policy Modeling*, 28, 25–38.

96. Furceri, D. and Zdzienicka, A. (2015). The Euro Area Crisis: Need for a Supranational Fiscal Risk Sharing Mechanism? *Open Economies Review*, 26(4), 683-710.

97. Gachter, M., Riedl, A. and Ritzberger-Grunwald, D. (2012). Business cycle synchronization in the Euro area and the impact of the financial crisis. *Monetary Policy and Economy*, 2, 33–60.

98. Garcia Herrero, A., and J. M. Ruiz. (2008). Do Trade and Financial Links Foster Business Cycle Synchronization in a Small Open Economy. *Moneda y Credito*, 226(1), 187–226.

99. Gavin, W. T. (2012). What Is Potential GDP and Why Does It Matter? Economic Synopses, Short essays and reports on the economic issues of the day, number 11. *Federal Reserve Bank of St. Louis*. Dostupno na: https://files.stlouisfed.org/files/htdocs/publications/es/12/ES_2012-04-20.pdf [pristupljeno 13.06.2018.].

100. Gelo, T. i Družić, M. (2015). Ukupna faktorska produktivnost sektora hrvatskoga gospodarstva. *Ekonomska misao i praksa*, 2, 327-344.

101. Giavazzi, F. and Spaventa, L. (2010). Why the current account may matter in a monetary union: Lessons from the financial crisis in the Euro area. CEPR Discussion Papers No. 8008. *Centre for Economic Policy Research.* Dostupno na: https://cepr.org/active/publications/discussion_papers/dp.php?dpno=8008 [pristupljeno 13.06.2018.].

102. Globan, T. (2018). *Troškovi uvođenja eura: Koliko su hrvatski poslovni ciklusi usklađeni s Eurozonom?* MacroHub, Dostupno na: https://macrohub.net.efzg.hr/analize/14-02-2018-uskla%C4%91enost-poslovnih-ciklusa [pristupljeno 13.06.2018.].

103. Gopinath, G., Kalemli-Ozcan, S., Karabarbounis, L. and Villegas-Sanchez, C. (2017). Capital Allocation and Productivity in South Europe. *The Quarterly Journal of Economics*, 132(4), 915–1967.

104. Gouveia, S. (2014). Business cycle correlation between the Euro area and the Balkan countries. *International Journal of Economic Sciences and Applied Research*, 7(1), 33-49.

105. Gouveia, S. and Correia, L. (2013). Trade Integration and Business Cycle Synchronization in the Euro Area: The Case of Southern European Countries. *Journal of Economic Integration*, 28(1), 85-107.

106. Grgić, M., Bilas, V. i Šimović, H. (2006). Financijska liberalizacija, monetarna i fiskalna politika Europske unije. *EFZG working paper series,* 14, 1-22. Dostupno na: https://hrcak.srce.hr/137200 [pristupljeno 13.06.2018.].

107. Guha, P., Daga, S., Gulati, R., Bhupal, G. and Oak, H. (2004). International Financial Markets Integration or Segmentation: A Case Study of Equity Markets. EconWPA Working Paper No. 0412013. Dostupno na: https://cepr.org/active/publications/discussion_papers/dp.php?dpno=8008 [pristupljeno 13.06.2018.].

108. Ferrari, A. and Picco, A. (2016). *International Risk Sharing in the EMU*. Working Papers 17, *European Stability Mechanism*. Dostupno na: https://www.esm.europa.eu/sites/default/files/wp17final.pdf. [pristupljeno 13.06.2018.].

109. Harding, D. and Pagan, A. (2002). Dissecting the cycle: a methodological investigation. *Journal of monetary economics*, 49(2), 365-381.

110. Hart, O. D. (1975). On the optimality of equilibrium when the market structure is incomplete. *Journal of Economic Theory,* 11(3), 418-443.

111. Havik, K., Morrow, K., Orlandi, F., Planas, C., Raciborski, R., Röger, W., Rossi, A., Thum-Thysen, A. and Vandermeulen, V. (2014). The Production Function Methodology for Calculating Potential Growth Rates & Output Gaps. Economic Papers 535. *European Commission.* Dostupno na: https://ec.europa.eu/economy_finance/publications/economic_paper/2014/pdf/ecp535_en.pdf [pristupljeno 13.06.2018.].

112. Helpman, E. (1984). A simple theory of international trade with multinational corporations. *Journal of Political Economy,* 92(3), 451-471.

113. Hildebrandt, A. and Moder, I. (2015). Business cycle synchronization between the Western Balkans and the European Union. *Focus on European Economic Integration,* 3, 8 – 25.

114. Ho, N. W. (2009). Financial Integration: Concepts and Impacts. *Macao Monetary Research Bulletin,* 10, 69-84.

115. Hoechle, D. (2007). Robust standard errors for panel regressions with cross-sectional dependence. *The Stata Journal,* 7(3), 281-312.

116. Hsu, C., Wu, J. and Yau, R. (2011). Foreign direct investment and business cycle co-movements: The panel data evidence. *Journal of Macroeconomics,* 33, 770–783.

117. Imbs, J. and Wacziarg, R. (2003). Stages of diversification. *The American Economic Review,* 93(1), 63-86.

118. Imbs, J. (2004). Trade, finance, specialization and synchronization. *The Review of Economics and Statistics*, 86(3), 723-734.

119. Imbs, J. (2006). The Real Effects of Financial Integration. *Journal of International Economics*, 68(2), 296-324.

120. Ingram, J. C. (1962). *Regional Payments Mechanisms. The case of Puerto Rico*. Chapel Hill: University of North Carolina Press.

121. Inklaar, R., Jong-A-Pin, R. and De Haan, J. (2008). Trade and business cycle synchronization in OECD Countries - A re-examination. *European Economic Review*, 52, 646–666.

122. Ishiyama, I. (1975). The Theory of Optimum Currency Areas: A Survey. *IMF Staff Papers*, 22(2), 344-383.

123. Jansen, J. and Stokman, A. (2004). Foreign direct investment and international business cycle comovement. Working Paper Series No. 401. *European Central Bank*. Dostupno na: https://www.ecb.europa.eu/pub/pdf/scpwps/ecbwp401.pdf [pristupljeno 13.06.2018.].

124. Jappelli, T. and Pagano, M. (2008). Financial Market Integration Under EMU. CSEF Working Paper No. 197. *Centre for Studies in Economics and Finance, University of Naples*. Dostupno na: http://www.csef.it/WP/wp197.pdf [pristupljeno 13.06.2018.].

125. Jovičić, G. (2017). Procjena potencijalnog rasta i jaza BDP-a u Hrvatskoj. HNB Pregledi P 38. *Hrvatska narodna banka*. Dostupno na: https://www.hnb.hr/documents/20182/2112241/p-038.pdf/87044a86-7326-406c-95b2-56b258ddf706 [pristupljeno 13.06.2018.].

126. Kalemli-Ozcan, S. and Manganelli, S. (2008) Financial Integration and Risk Sharing: The Role of the Monetary Union. in 5th European Central Banking Conference on The Euro at Ten: Lessons and Challenges, Frankfurt: ECB.

127. Kalemli-Ozcan, S., Papaioannou, E. and Peydro, J. (2013). Financial Regulation, Financial Globalization, and the Synchronization of Economic Activity. *Journal of Finance*, 68(3), 1179-1228.

128. Kalemli-Ozcan, S., Sorensen, B. and Yosha, O. (2003). Risk Sharing and Industrial Specialization: Regional and International Evidence. *American Economic Review*, 93(3), 903-918.

129. Kamanduliene, A. and Lydeka, Z. (2011). Methodological aspects of business cycle synchronization research. *Applied Economics: Systematic Research*, 5(2), 37-50.

130. Kappler, M. and Sachs, A. (2013). *Business cycle synchronisation and economic integration: new evidence from the EU* (Vol. 45). Berlin: Springer Science & Business Media.

131. Kehoe, P. and Perri, F. (2002). International business cycles with endogenous incomplete markets. *Econometrica*, 70(3), 907-928.

132. Kenen, P. (1969). The theory of optimum currency areas: An eclectic view. In Mundell R. A. and Swoboda A.K. (Eds.), *Monetary problems of the international economy*, Chicago: University of Chicago Press, 41-60.

133. Kollmann, R. (1996). Incomplete asset markets and the cross-conutry consumpsion corelation puzzle. *Journal of Economics Dynamics and Control*, 20, 945-961.

134. Koopman, S. J. and Azevedo, J. V. (2003). Measuring synchronization and convergence of business cycles. Tinbergen Institute Discussion Paper No. 03-052/4. *Tinbergen Institute*. Dostupno na: https://papers.tinbergen.nl/03052.pdf [pristupljeno 13.06.2018.].

135. Kopits, G. (1999). Implications of EMU for Exchange Rate Policy in Central and Eastern Europe. IMF Working Paper WP/99/9. *International Monetary Fund*. Dostupno na: https://www.imf.org/en/Publications/WP/Issues/2016/12/30/Implications-of-EMU-for-Exchange-Rate-Policy-in-Central-and-Eastern-Europe-2876 [pristupljeno 13.06.2018.].

136. Kose, A., Prasad, E. and Terrones, M. (2003). How Does Globalization Affect the Synchronization of Business Cycles? *American Economic Review Papers and Proceedings*, 93(4), 57–62.

137. Kotarac, K., Kunovac, D. i Ravnik, R. (2017). *Usklađenost poslovnih ciklusa i ekonomskih šokova između Hrvatske i država europodručja*. HNB Istraživanja, I-51. Hrvatska narodna banka. Dostupno na: https://euro.hnb.hr/documents/2070751/2104183/i-051.pdf/cc59ee57-c63a-4d49-8798-6fc7107aec7d [pristupljeno 13.06.2018.].

138. Kovačić, Z. and Vilotić, M. (2017). Assessing European business cycles synchronization. MPRA Paper No. 79990. *Munich Personal RePEc Archive*. Dostupno na: https://mpra.ub.uni-muenchen.de/79990/1/MPRA_paper_79990.pdf [pristupljeno 13.06.2018.].

139. Krugman, P. (1991). *Geography and Trade*. Cambridge: MIT Press.

140. Krugman, P. (1993). Lessons of massachusettes for EMU. In: Giavvazzi, F and Torres, F. (Eds). *The transition to economic and monetary union in Europe*. New York: Cambridge University Press, 241–261.

141. Krugman, P. (2008). The International Finance Multiplier. Dostupno na: https://www.princeton.edu/~pkrugman/finmult.pdf [pristupljeno 13.06.2018.].

142. Kuenzel, R. And Ruscher, E. (2013). The future of EMU. ECFIN Economic Brief Issue 22. *European Commission*. Dostupno na: https://ec.europa.eu/economy_finance/publications/economic_briefs/2013/pdf/eb22_en.pdf [pristupljeno 13.06.2018.].

143. Kundera, J. (2012). The theory of an "optimum currency area". *Wroclaw Review of Law, Administration & Economics,* 2(2), 1–28.

144. Kunovac, M. i Pufnik, A. (2015). Obilježja tržišta rada i određivanja plaća u Hrvatskoj: rezultati Ankete poduzeća. Pregledi P-27. *Hrvatska narodna banka*. Dostupno na: https://www.hnb.hr/documents/20182/265578/p-027/28c3339e-b94a-4fc6-8c0a-626f1738a6cb [pristupljeno 13.06.2018.].

145. Kunroo, M. H. (2015). Theory of Optimum Currency Areas: A Literature Survey. *Review of Market Integration,* 7(2), 87–116.

146. Lane, P. R. and Milesi-Ferretti, G. M. (2012). External adjustment and the global crisis. *Journal of International Economics,* 88(2), 252–265.

147. Lane, P. R. and Milesi-Ferretti, G. M. (2014). Global imbalances and external adjustment after the crisis. IMF Working Paper WP/14/151. *International Monetary Fund.* Dostupno na: https://www.imf.org/external/pubs/ft/wp/2014/wp14151.pdf [pristupljeno 13.06.2018.].

148. Lee, G. H. and Azali, M. (2010). The endogeneity of the optimum currency area criteria in East Asia. *Economic Modelling,* 27(1), 165-170.

149. Levine, R. (1997). Financial development and economic growth: views and agenda. *Journal of Economic Literature,* 35, 688-726.

150. Levine, R. (2001). International financial liberalization and economic growth. *Review of International Economic,* 9, 688–702.

151. Liebscher, K., Christl, J., Mooslechner, P. and Ritzberger-Grünwald, D. (2006). *Financial development, integration and stability: evidence from Central, Eastern and South-Eastern Europe*. Cheltenham: Edward Elgar Publishing.

152. Lubik, T. and Slivinski, S. (2010). Is the Output Gap a Faulty Gauge for Monetary Policy? Economic Brief EB10-01. *Federal Reserve Bank of Richmond*. Dostupno na: https://www.richmondfed.org/~/media/richmondfedorg/publications/research/economic_brief/2010/pdf/eb_10-01.pdf [pristupljeno 13.06.2018.].

153. Lukmanova, E. and Tondl, G. (2017). Macroeconomic imbalances and business cycle synchronization. Why common economic governance is imperative for the Eurozone. *Economic Modelling,* 62, 130-144.

154. Ljubaj, I., Martinis, A. i Mrkalj, M. (2010). Priljev kapitala i učinkovitost sterilizacije – ocjena koeficijenta sterilizacije i ofset koeficijenta. HNB istraživanja I-26. *Hrvatska narodna banka*. Dostupno na: https://www.hnb.hr/documents/20182/121342/i-026.pdf/6aa8ed14-6924-476a-bb03-5829b8a412f8 [pristupljeno 13.06.2018.].

155. Magnifico, G. (1971). European monetary unification for balanced growth: a new approach. *Essays in International Finance*, 88, Princeton: Princeton University.

156. Marconi, D. and Upper, C. (2017). Capital misallocation and financial development: a sector-level analysis. BIS Working Papers No 671. *Bank for International Settlements*. Dostupno na: https://www.bis.org/publ/work671.pdf [pristupljeno 13.06.2018.].

157. Markusen, J. R. and Venables, A. J. (2000). The theory of endowment, intra-industry and multi-national trade. *Journal of International Economics,* 52(2), 209-234.

158. Massmann, M., and Mitchell, J. (2004). Reconsidering the Evidence: Are Eurozone Business Cycles Converging? *Journal of Business Cycle Measurement and Analysis*, 1(3), 275-308.

159. McKinnon, R. (1963). Optimum currency areas. *American Economic Review*, 53, 717-725.

160. McKinnon, R. (2004). Optimum Currency Areas and Key Currencies: Mundell I vs. Mundell II. *Journal of Common Market Studies,* 42(4), 689– 715.

161. Melitz, J. (2001). Geography, Trade and Currency Union. CEPR Discussion Paper No. 2987. *Centre for Economic Policy Research.* Dostupno na: https://ssrn.com/abstract=287308 [pristupljeno 13.06.2018.].

162. Mendoza, E. G. and Quadrini, V. (2010). Financial globalization, financial crises and contagion**.** *Journal of Monetary Economics,* 57, 24–39.

163. Milano, V. and Reichlin, P. (2017). Risk sharing across the US and EMU: The role of public institutions. Policy Brief – January 9, 2017. *LUISS School of European Political*

Economy. Dostupno na: https://sep.luiss.it/sites/sep.luiss.it/files/Reichlin_PB_01092017_0.pdf [pristupljeno 13.06.2018.].

164. Mink, M., Jacobs, J. P. A. M. and De Haan, J. (2009). Measuring the Similarity of Business Cycles in the Euro Area and the US. CESifo Working Paper No. 2112. *CESifo Group Munich*. Dostupno na: https://www.ifo.de/DocDL/cesifo1_wp2112.pdf [pristupljeno 13.06.2018.].

165. Mintz, N. (1970). *Monetary Union and Economic Integration*. New York: New York University Press.

166. Mongelli, F. P. (2002). „New“ Views on the Optimum Currency Area Theory: What is EMU Telling Us?. ECB Working Paper No. 138. *European Central Bank.* Dostupno na: https://ssrn.com/abstract=357400 [pristupljeno 13.06.2018.].

167. Mongelli, F. P. (2008). European economic and monetary integration and the optimum currency area theory. Economic Papers 302. *European Commission.* Dostupno na: https://ec.europa.eu/economy_finance/publications/pages/publication12081_en.pdf [pristupljeno 13.06.2018.].

168. Morgan, D. P., Rime, B. and Strahan, P. E. (2004). Bank Integration and State Business Cycles. *The Quarterly Journal of Economics,* 119(4), 1555–1584.

169. Mundell, R. A. (1961). A theory of optimum currency areas. *American Economic Review*, 51, 657-665.

170. Mundell, R. A. (1973). Uncommon Arguments for Common Currencies, In: Johnson, H. G. and Swoboda, A.K. (eds.), *The Economics of Common Currencies*, London: George Allen and Unwin Ltd, 114-132.

171. Nilsson, R. and Gyomai, G. (2011). Cycle extraction: a comparison of the Phase-Average Trend method, the Hodrick-Prescott and Christiano-Fitzgerald filters. OECD Statistics Working Papers 2011/4. *OECD Publishing*. Dostupno na: https://www.oecd-ilibrary.org/docserver/5kg9srt7f8g0-en.pdf?expires=1578487093&id=id&accname=guest&checksum=81B1C6C8EBD657C9195AEEDFEF9BCF64 [pristupljeno 13.06.2018.].

172. Njegić, J., Živkov, D. and Damnjanović, J. (2017). Business cycles synchronisation between the EU-15 and selected Eastern European Countries - The wavelet coherence approach. *Acta Oeconomica,* 67(4), 539–556.

173. Obradović, S. i Mihajlović, V. (2013) Synchronization of business cycles in the selected European countries. *Panoeconomicus,* 60(6), 759 – 773.

174. Obstfeld, M. (1994). Risk-Taking, Global Diversification, and Growth. *The American Economic Review*, 84(5), 1310-1329.

175. Otker-Robe, I., Polanski, Z., Topf, B. i Vavra, D. (2007). Coping with Capital Inflows: Experiences of Selected European Countries. IMF Working paper WP/07/190. *International Monetary Fund.* Dostupno na: https://www.imf.org/external/pubs/ft/wp/2007/wp07190.pdf [pristupljeno 13.06.2018.].

176. Otto, G., Voss, G. and Willard, L. (2001). Understanding OECD Output Correlations. RBA Research Discussion Papers 2001-05. *Reserve Bank of Australia*. Dostupno na: https://www.rba.gov.au/publications/rdp/2001/pdf/rdp2001-05.pdf [pristupljeno 13.06.2018.].

177. Parks, R. (1967). Efficient estimation of a system of regression equations when disturbances are both serially and contemporaneously correlated. *Journal of the American Statistical Association*, 62, 500-509.

178. Pasimeni, P. (2015). The Economic Rationale of an EMU Fiscal Capacity. Proceedings of OeNB Workshop Toward a Genuine Economic and Monetary Union. *Oesterreichische Nationalbank*. Dostupno na: https://ssrn.com/abstract=3216390 [pristupljeno 13.06.2018.].

179. Patterson, B. and Amati, S. (1998). Adjustment to Asymmetric Shocks. Working Paper Economic Affairs Series ECON-104. *European Parliament.* Dostupno na: http://www.europarl.europa.eu/workingpapers/econ/pdf/104_en.pdf [pristupljeno 13.06.2018.].

180. Persson, T. (2001). Currency Unions and Trade: How Large is the Treatment Effect? *Economic Policy*, 16(33), 433-448.

181. Pontiners, V. and Parulian, F. (2010). Business Cycle Synchronization and Financial Integration in the Asia-Pacific Region, In: Findlay, C., Parulian, F. and Corbett, J. (eds.), *Linkages between Real and Financial Aspects of Economic Integration in East Asia*, Jakarta: ERIA, 94-129.

182. Razin, A., Sadka, E. and Yuen, C. (1999). Excessive FDI flows under asymmetric information. NBER Working Paper 7400. *National Bureau of Economic Research.* Dostupno na: https://www.nber.org/papers/w7400 [pristupljeno 13.06.2018.].

183. Reis, R. (2013). The Portuguese Slump and Crash and the Euro Crisis. *Brookings Papers on Economic Activity*, 46(1), 143-210.

184. Rogić, L. (2011). Održivost deficita tekućeg računa bilace plaćanja u Republici Hrvatskoj. *Zbornik Ekonomskog fakulteta u Zagrebu*, 9(2), 17-33.

185. Rose, A. and Wincoop, E. (2001). National Money as a barrier to trade: the real case for currency union. *American Economic Review*, 91(2), 386-390.

186. Rose, A., Lockwood, B. and Quah, D. (2000). One Money, One Market: The Effect of Common Currencies on Trade. *Economic Policy*, 15(30), 7-45.

187. Rotemberg, J. J. (1999). A heuristic method for extracting smooth trends from economic time series. NBER Working Paper 7439. *National Bureau of Economic Research*. Dostupno na: http://www.nber.org/papers/w7439 [pristupljeno 13.06.2018.].

188. Ruscher, E. (2015). An overview of market-based adjustment in the euro area in the light of the crisis. *Quarterly Report on the Euro Area*, 14(4), 7-17.

189. Sanchez, D. J. L. and Varoudakis, A. (2013). Growth and Competitiveness as Factors of Eurozone External Imbalances: Evidence and Policy Implications. Policy Research Working Paper; No. 6732. *The World Bank*. Dostupno na: https://ssrn.com/abstract=2372195 [pristupljeno 13.06.2018.].

190. Sanchis i Marco, M. (2014). *The Economics of the Monetary Union and the Eurozone Crisis*, SpringerBriefs in Economics, DOI 10.1007/978-3-319-00020-6.

191. Saint-Paul, G. (1992). Technological choice, financial markets and economic development. *European Economic Review*, 34, 763-781.

192. Schiavo, S. (2008). Financial integration, GDP correlation and the endogeneity of optimum currency areas. *Economica*, 75(297), 168-189.

193. Schmitz, B. and Hagen, J. (2011). Current account imbalances and financial integration in the euro area. *Journal of International Money and Finance*, 30, 1676–1695.

194. Siedschlag, I. (2010), Patterns and determinants of business cycle synchronization in the enlarged European Economic and Monetary Union. *Eastern Journal of European Studies*, 1(1), 21-44.

195. Siedschlag, I. and Tondl, G. (2011). Regional output growth synchronisation with the Euro Area. *Empirica*, 38, 203–221.

196. Silva, S. and Tenreyro, S. (2010). Currency Unions in Prospect and Retrospect. *The Annual Review of Economics*, 2, 51–74.

197. Stavarek, D., Repkova, I. and Gajdošova, K. (2012). Theory of financial integration and achievements in the European Union, In: Matoušek, R. and Stavarek, D. (eds.), *Financial Integration in the European Union*, London: Routledge.

198. Stockhammer, E. and Kohler, K. (2019). Financialization and demand regimes in advanced economies. Working paper 1911. *Post Keynesian Economics Society*. Dostupno na: http://www.postkeynesian.net/downloads/working-papers/PKWP1911.pdf [pristupljeno 13.06.2018.].

199. Ševela, M. (2016). Role of Foreign Direct Investment Stock in Business cycle synchronization. *Procedia - Social and Behavioral Sciences*, 220, 506 – 512.

200. Šimović, H., Ćorić, T. i Deskar-Škrbić, M. (2014). Mogućnosti i ograničenja fiskalne politike u Hrvatskoj. *Ekonomski pregled*, 65(6), 541-575.

201. Škuflić, L. i Vlahinić-Dizdarević, N. (2004). Koliko je hrvatska robna razmjena intra-industrijska? *Ekonomski pregled*, 55(9-10), 727-751. Dostupno na: https://hrcak.srce.hr/16313 [Pristupljeno: 13.06.2018.]

202. Šonje, V. i Vrbanac, I. (2000). Mjerenje sličnosti gospodarskih kretanja u srednjoj Europi: Povezanost poslovnih ciklusa Njemačke, Mađarske, Češke i Hrvatske. *Ekonomski pregled*, 51 (9-10), 895-917.

203. Tomić, D. i Demanuele, D. (2017). Synchronicity and similarity of business cycles; Croatia vis a vis new EMU countries. *Review of Innovation and Competitiveness*, 3(4), 31-56.

204. Tower, E. and Willet, T. (1976). *The Theory of Optimum Currency Areas and Exchange Rate Flexibility*. Special Papers in International Economics, 11, Princeton: Princeton University.

205. Traistaru, I. (2004). Transmission channels of business cycles synchronization in an enlarged EMU. ZEI Working paper No. B 18-2004. *Center for European Integration Studies, University of Bonn.* Dostupno na: https://www.econstor.eu/bitstream/10419/39537/1/396488617.pdf [pristupljeno 13.06.2018.].

206. Tripier, F. (2002). The dynamic correlation between growth and unemployment. *Economics Bulletin*, 5(4), 1-9.

207. Vaubel, R. (1976). Real exchange-rate changes in the European community: the empirical evidence and its implications for European currency unification. *Weltwirschaftliches Archiv*, 112(3), 429–470.

208. Vlada Republike Hrvatske i HNB (2018). *Strategije za uvođenje eura kao službene valute Hrvatskoj*. Dostupno na: https://vlada.gov.hr/UserDocsImages/Vijesti/2017/10%20listopad/30%20listopada/Strategija%20za%20uvo%C4%91enje%20eura%20kao%20sluz%CC%8Cbene%20valute%20u%20Hrvatskoj.pdf [pristupljeno 13.06.2018.].

209. Woitek, U. (1998). A Note on the Baxter-King Filter. Working Papers Series 9813. Business School - Economics, University of Glasgow. Dostupno na: http://www.gla.ac.uk/media/media_219052_en.pdf [pristupljeno 13.06.2018.].

210. Wyplosz, C. (2013). *Eurozone Crisis: It's About Demand, not Competitiveness*. Geneva: The Graduate Institute.

211. Xing, T. and Abbott, A. (2007). The Effects of Trade, Specialisation and Financial Integration for Business Cycle Synchronisation. *Department of Economics, University of Bath.* Dostupno na: http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.630.4633&rep=rep1&type=pdf [pristupljeno 13.06.2018.].

212. Zarnowitz, V. and Ozyildirim, A. (2006). Time series decomposition and measurement of business cycles, trends and growth cycles. *Journal of Monetary Economics*, 53(7), 1717-1739.

POPIS GRAFIKONA

Grafikon 1. Usklađenost poslovnih ciklusa Hrvatske sa zemljama eurozone (BCS) 133
Grafikon 2. Financijska integracija (FI1) Hrvatske sa zemljama eurozone 136
Grafikon 3. Financijska integracija (FI3) Hrvatske sa zemljama eurozone (2001.-2016.) 138
Grafikon 4. Trgovinska integracija Hrvatske sa zemljama Eurozone (TI1) 141
Grafikon 5. Sličnost sektorske strukture Hrvatske i sektorskih struktura zemalja eurozone (SS5) 144
Grafikon 6. Konvergencija fiskalne politike Hrvatske sa zemljama eurozone 147
Grafikon 7. Dijagrami rasipanja s procijenjenim regresijskim pravcem 158
Grafikon 8. Stanje dolaznih izravnih stranih investicija iz zemalja eurozone u Hrvatsku 174
Grafikon 9. Stanje odlaznih izravnih stranih investicija iz Hrvatske u zemlje eurozone 174
Grafikon 10. Realna stopa povrata na desetogodišnje obveznice 175
Grafikon 11. Dijagrami rasipanja (2001.-2008.) 178
Grafikon 12. Dijagrami rasipanja (2009.-2016.) 181
Grafikon 13. Realni i nominalni efektivni devizni tečaj 194
Grafikon 14. Bruto dodana vrijednost sektora Hrvatske (2001.-2016.) 195
Grafikon 15. Izračun rasta - prosjek za 2002.-2008. (%); prosjek za 2008.-2013. (%) 198
Grafikon 16. Dijagrami rasipanja FI-TI 200
Grafikon 17. Robna razmjena Hrvatske sa zemljama eurozone u mil. eura (2001.-2016.) 209

POPIS SLIKA

Slika 1. Shematski prikaz istraživačkih hipoteza 18
Slika 2. Trgovinska integracija, usklađenost poslovnih ciklusa i izbor monetarnog režima 51
Slika 3. Endogenost optimalnog valutnog područja 52
Slika 4. Hipoteza o specijalizaciji 54
Slika 5. Savršena fazna usklađenost poslovnih ciklusa s različitim amplitudama 57
Slika 6. Niska korelacija zbog faznog pomaka 58
Slika 7. Različita amplituda i fazni pomak 59
Slika 8. Devijacijski poslovni ciklusi 62
Slika 9. Koristi financijske integracije 89
Slika 10. Troškovi financijske integracije 93
Slika 11. Kanali utjecaja financijske integracije na usklađivanje poslovnih ciklusa 113
Slika 12. Empirijski model utjecaja financijske integracije na usklađivanje poslovnih ciklusa 124

POPIS TABLICA

Tablica 1. Sumarni prikaz kanal utjecaja financijske integracije na usklađivanje poslovnih ciklusa 119
Tablica 2. Deskriptivna statistika 151
Tablica 3. Korelacijska matrica 155
Tablica 4. Analiza faktora inflacije varijance nezavisnih varijabli 156
Tablica 5. Studentov t-test jednakosti artimetičkih sredina zavisne varijable (BCS) 162
Tablica 6. Hausmanov test 162
Tablica 7. Rezultati Wooldridgeovog testa i modificiranog Waldovog testa 163
Tablica 8. Rezultati panela 1a. 164
Tablica 9. Rezultati panela 1b. (2009.-2016.) 169
Tablica 10. Rezultati t-testa zavisne varijable (logSS2) panela 2. 176
Tablica 11. Rezultati t-testa zavisne varijable (logSS5) panela 2. 176
Tablica 12. Wooldridgeov test i modificirani Waldov test logSS2 (2001.-2008.) 184
Tablica 13. Wooldridgeov test i modificirani Waldov test (logSS5) (2001.-2008.) 184
Tablica 14. Rezultati panela 2a. (2001.-2008.) 185
Tablica 15. Rezultati panela 2b. (2001.-2008.) 187
Tablica 16. Wooldridgeov test i modificirani Waldov test (logSS2) (2009.-2016.) 189
Tablica 17. Wooldridgeov test i modificirani Waldov test (logSS5) (2009.-2016.) 189
Tablica 18. Rezultati panela 2c. (2009.-2016.) 191
Tablica 19. Rezultati panela 2d. (2009.-2016.) 193
Tablica 20. T-test jednakosti artimetičkih sredina zavisne varijable (logTI1) panela 3 199
Tablica 21. T-test jednakosti artimetičkih sredina zavisne varijable (logTI2) panela 3 199
Tablica 22. Hausmanov test (logTI1) 202
Tablica 23. Wooldridgeov test autokorelacije i modificirani Waldov test (logTI1) 203

Tablica 24. Hausmanov test (logTI2) 204
Tablica 25. Wooldridgeov test autokorelacije i modificirani Waldov test (logTI2) 204
Tablica 26. Rezultati panela 3a. 206
Tablica 27. Rezultati panela 3b. 207

PRILOZI

Prilog 1. Kretanje poslovnog ciklusa Hrvatske u odnosu na poslovne cikluse zemalja eurozone

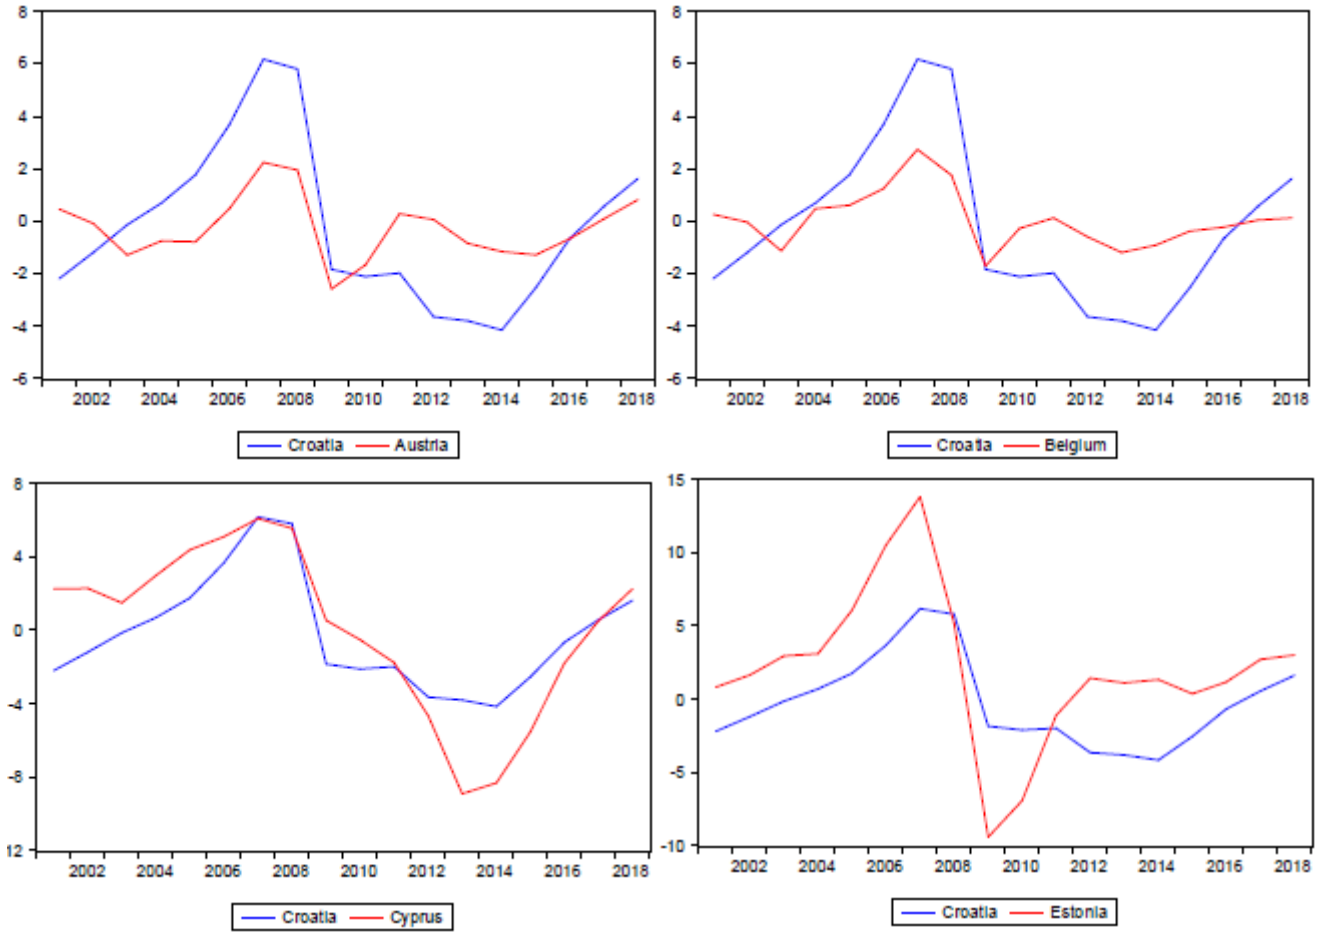

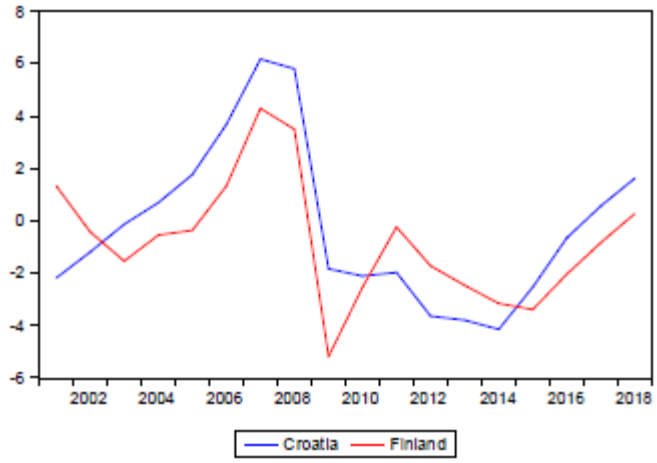
Croatia
Finland

Croatia
France

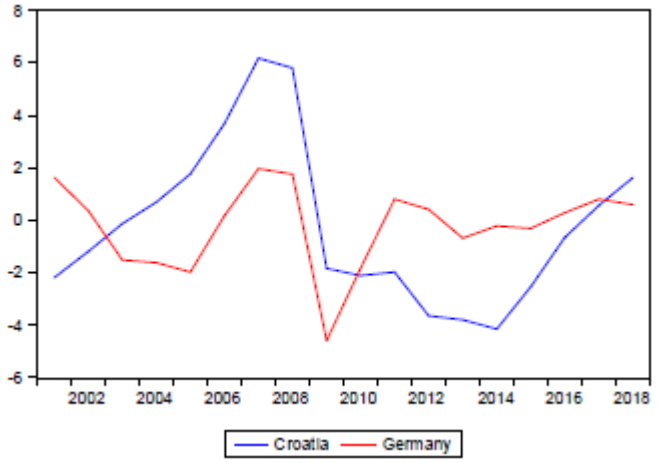
Croatia
Germany

Croatia
Greece

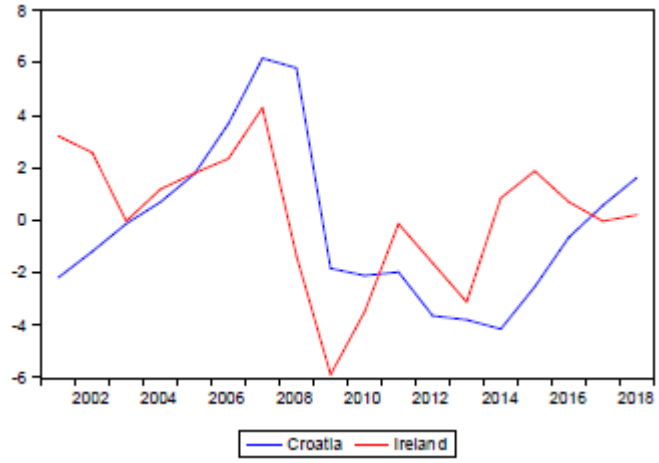
Croatia
Ireland

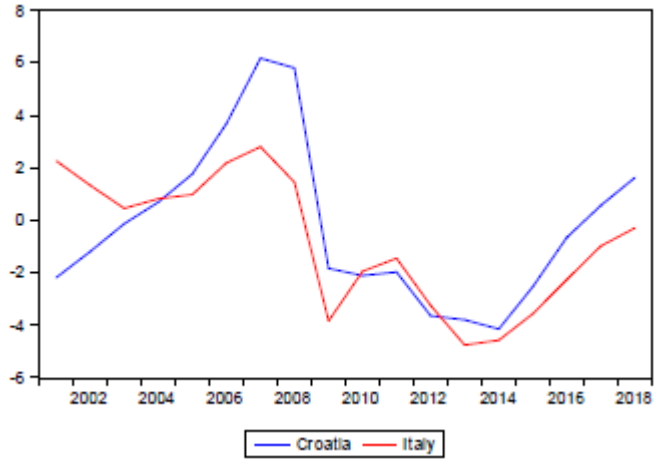
Croatia
Italy

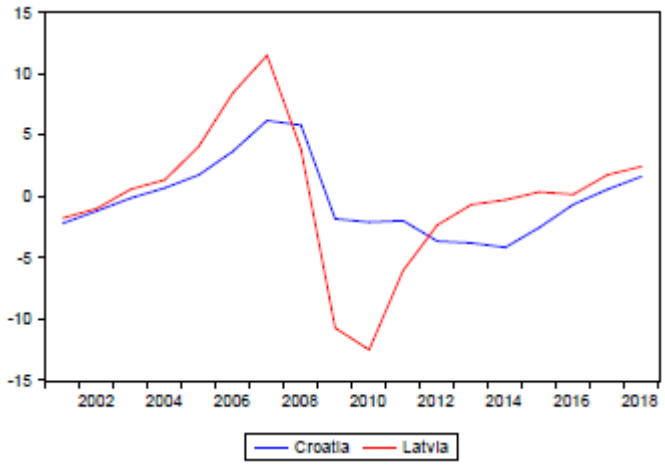
Croatia
Latvia

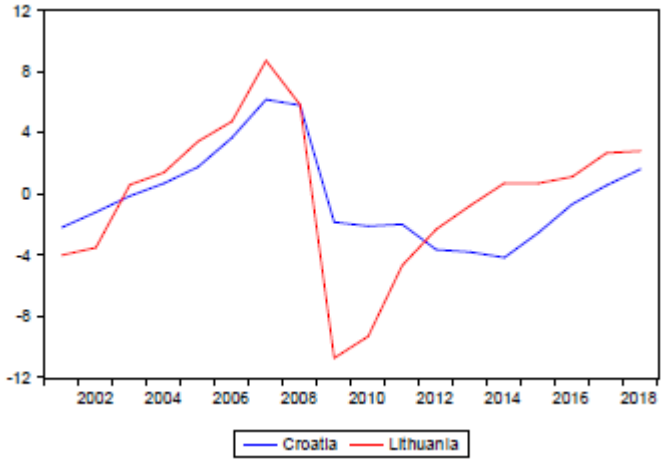
Croatia
Lithuania

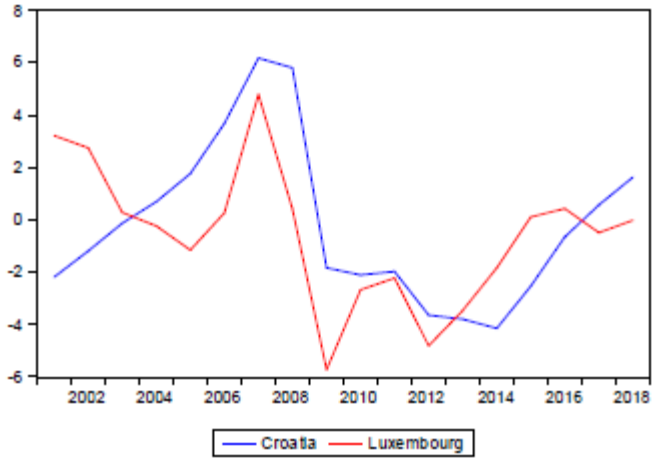
Croatia
Luxembourg

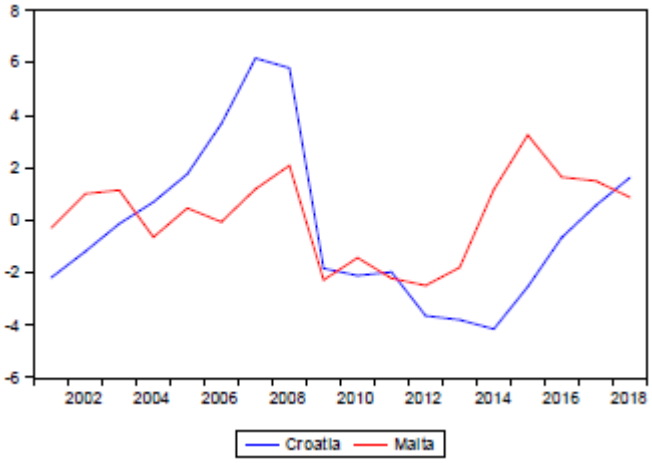
Croatia
Malta

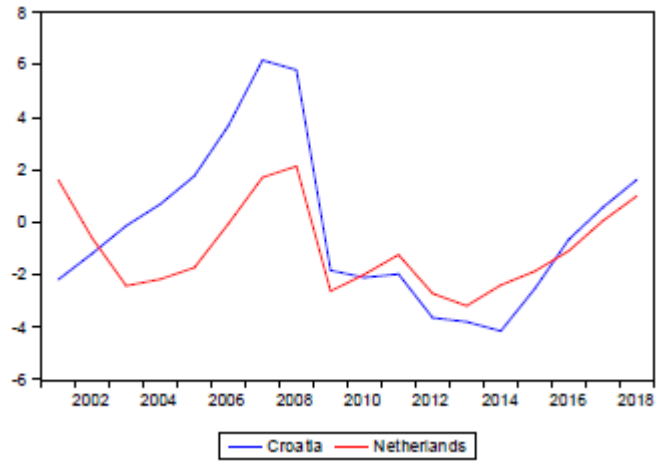
Croatia
Netherlands

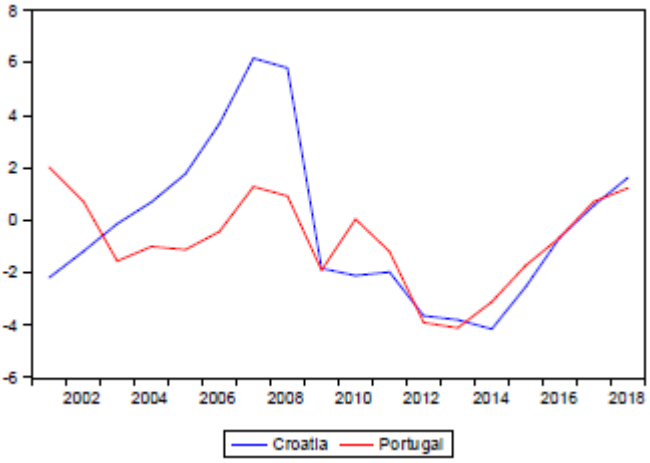
Croatia
Portugal

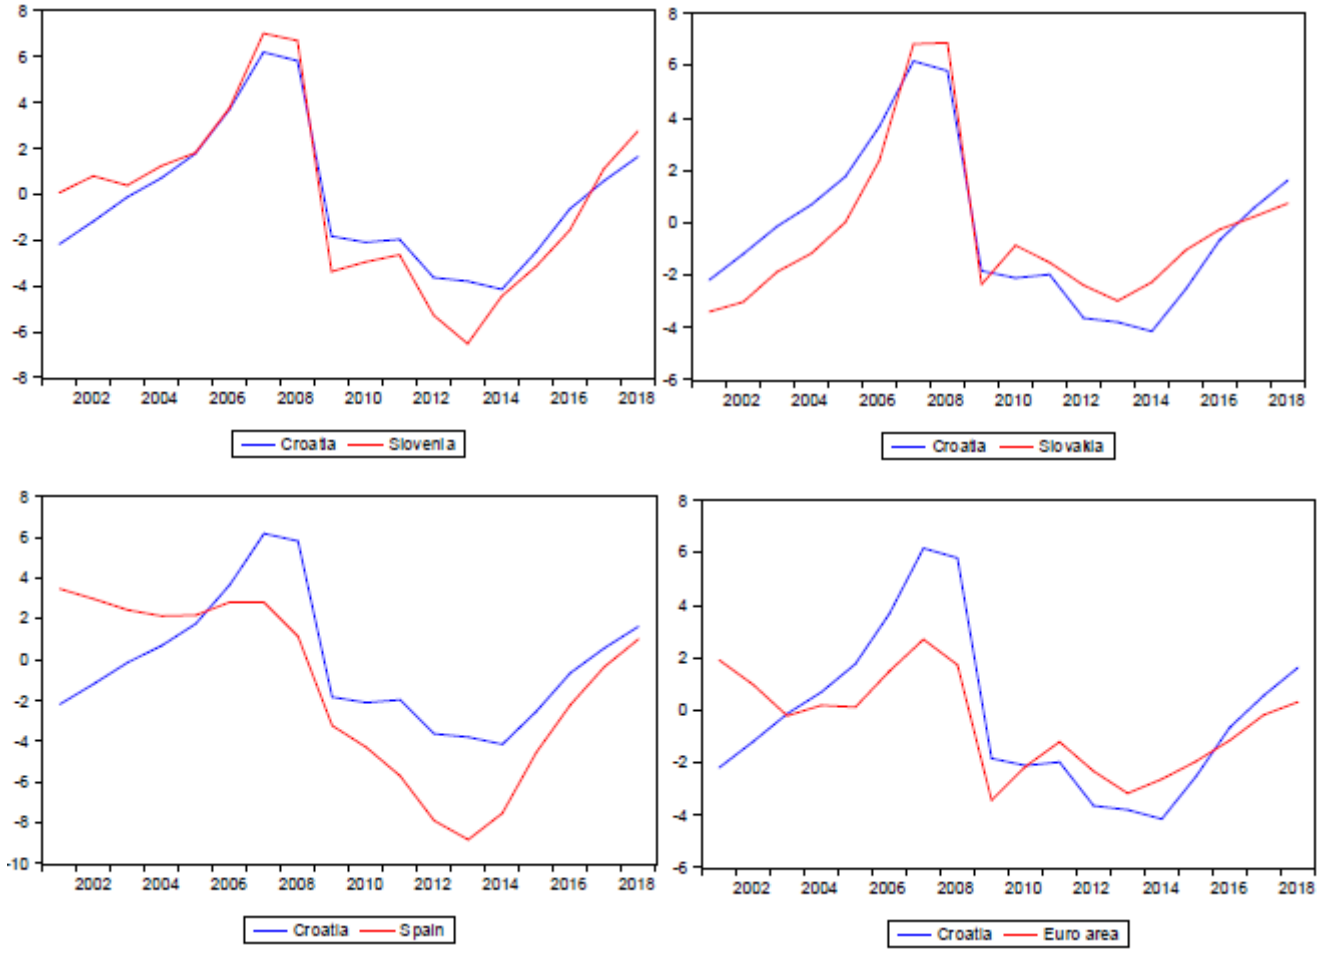

Izvor: Izrada autora (EViews 9)

Prilog 2. Dijagrami rasipanja FI1-BCS Hrvatska sa zemljama eurozone (pojedinačno)

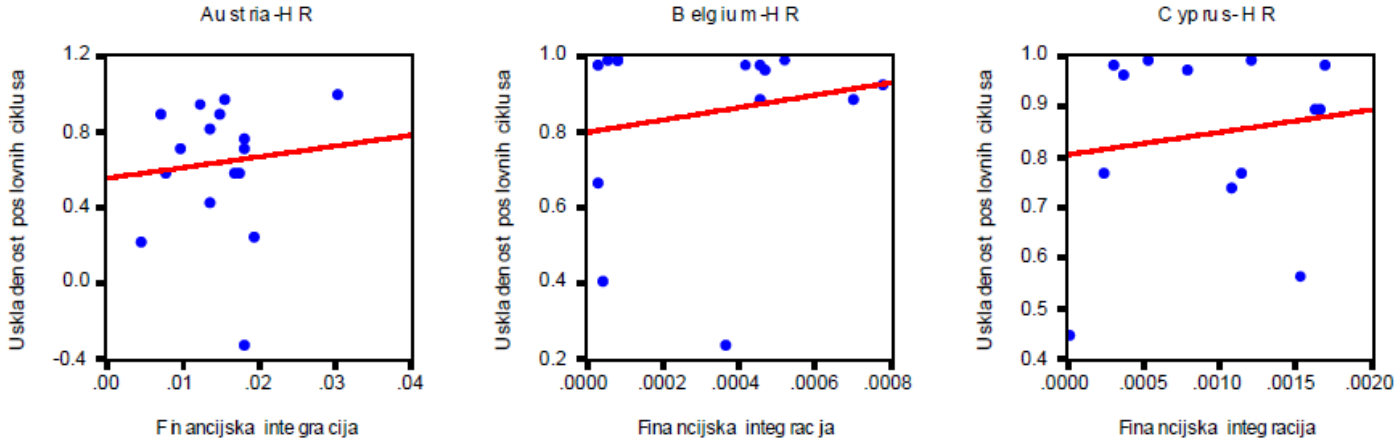

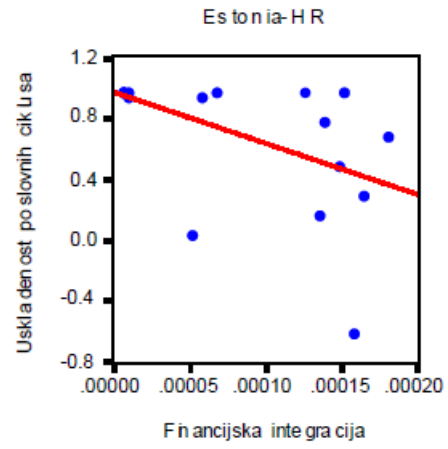
Estonia-HR
Usklađenost poslovnih ciklusa
Financijska integracija

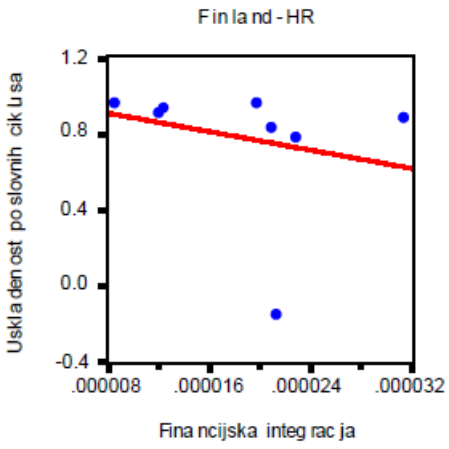
Finland-HR
Usklađenost poslovnih ciklusa
Finansijska integracija

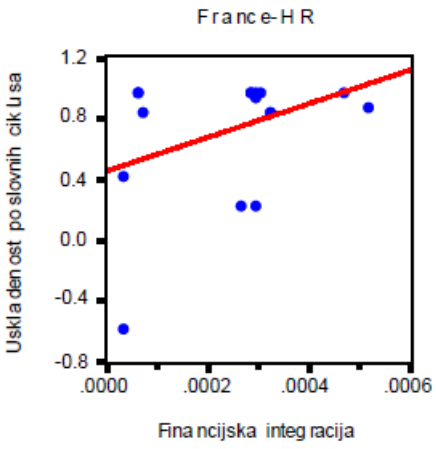
France-HR
Usklađenost poslovnih ciklusa
Finansijska integracija

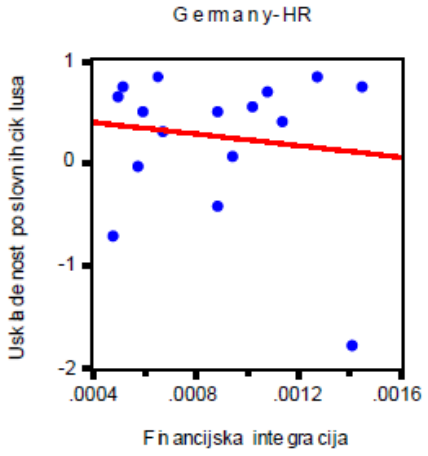
Germany-HR
Usklađenost poslovnih ciklusa
Financijska integracija

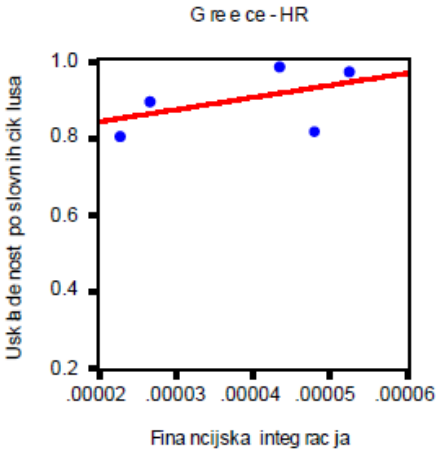
Greece-HR
Usklađenost poslovnih ciklusa
Finansijska integracija

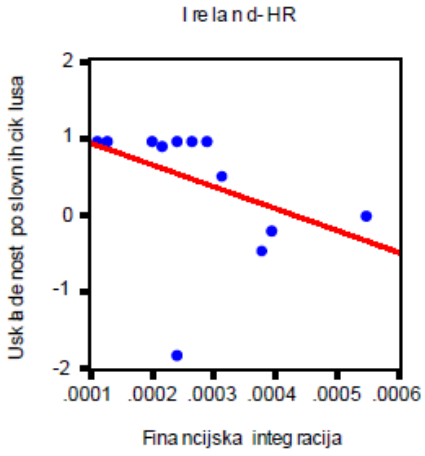
Ireland-HR
Usklađenost poslovnih ciklusa
Finansijska integracija

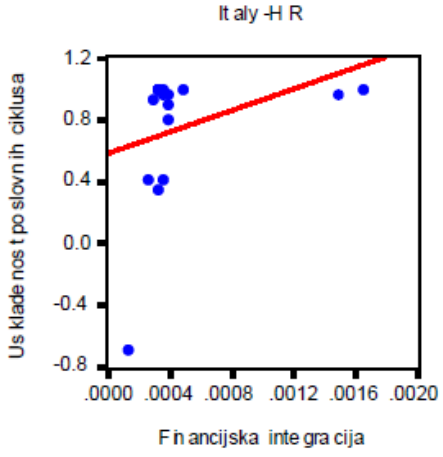
Italy-HR
Usklađenost poslovnih ciklusa
Financijska integracija

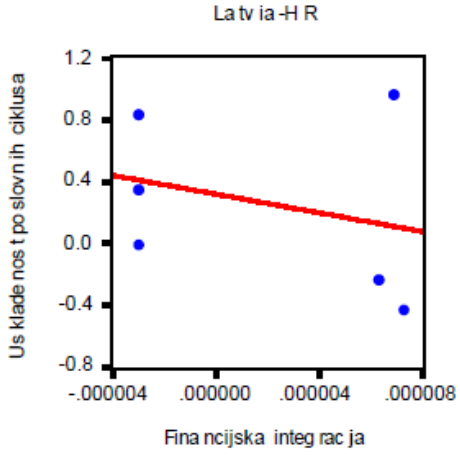
Latvia-HR
Usklađenost poslovnih ciklusa
Finansijska integracija

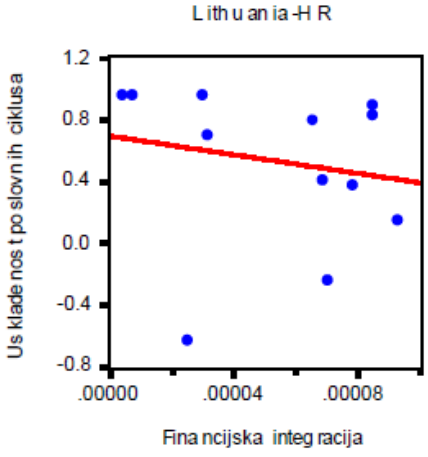
Lithuania-HR
Usklađenost poslovnih ciklusa
Finansijska integracija

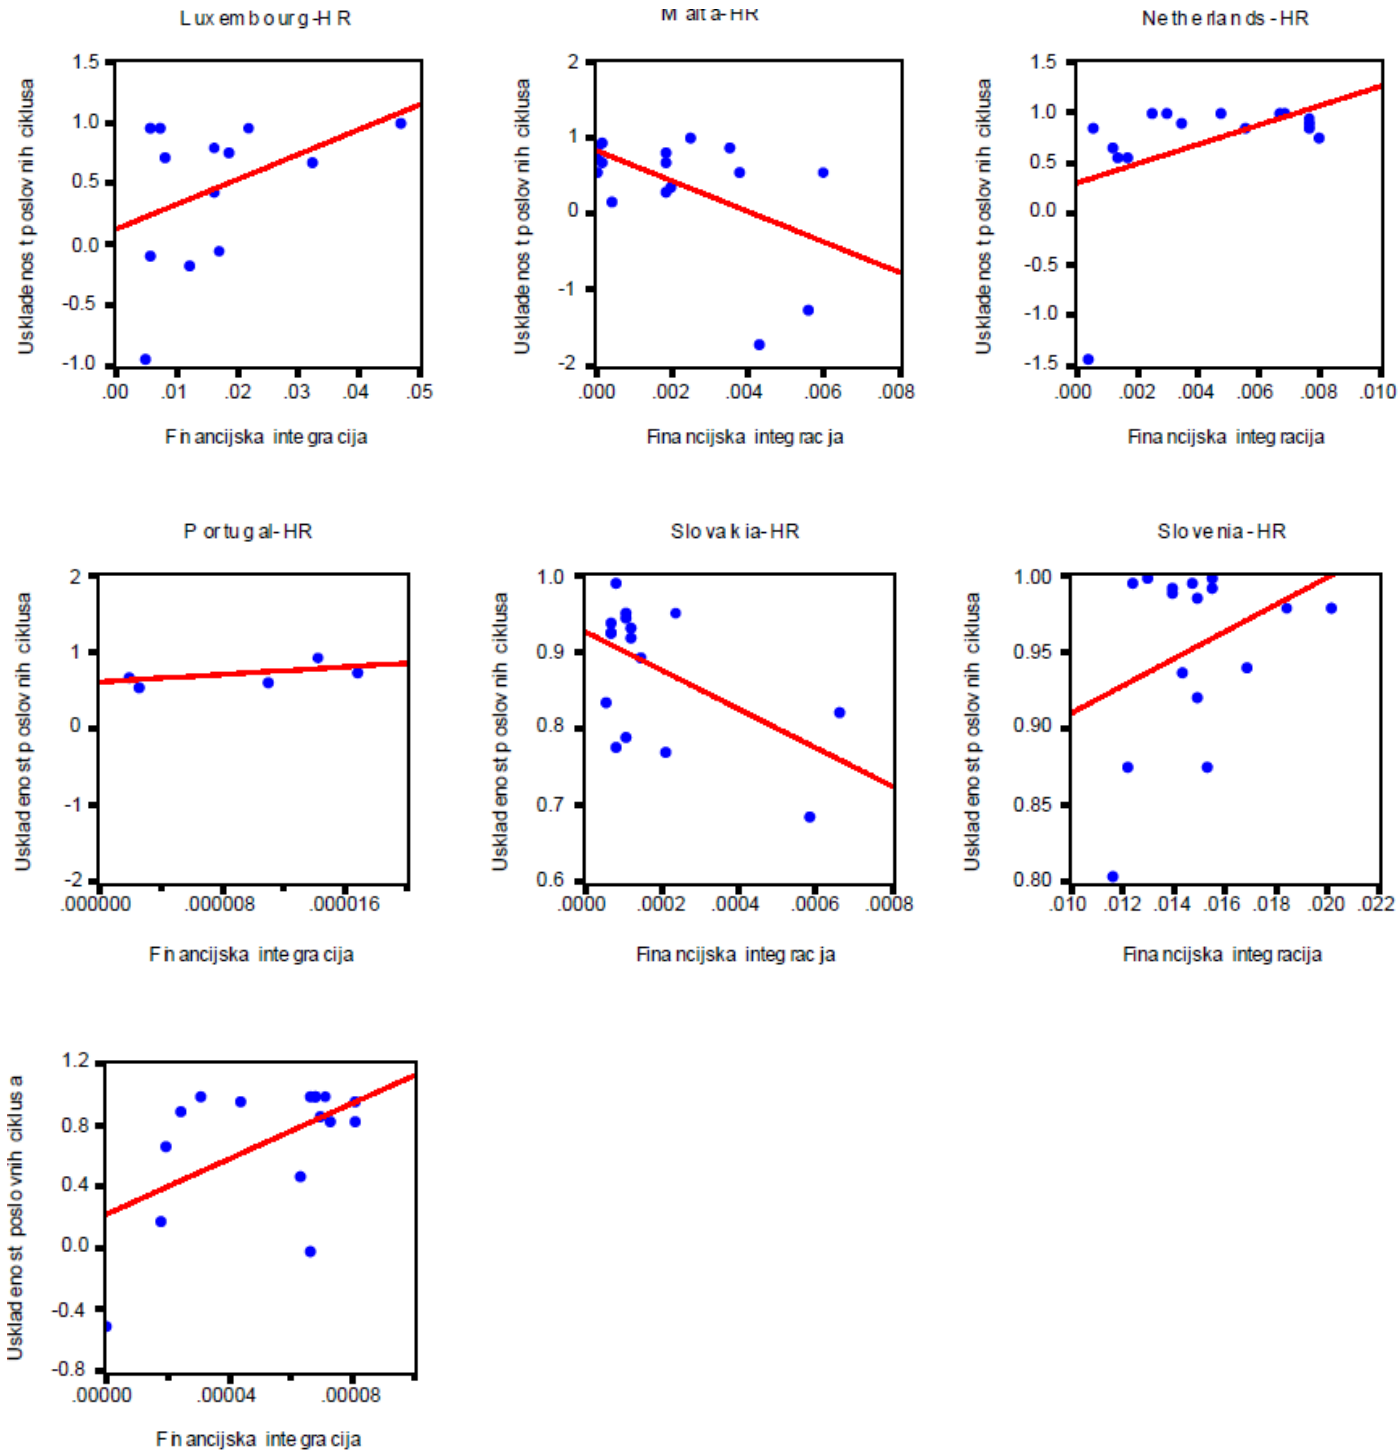

Izvor: Izrada autora (EViews 9)

Prilog 3. Dijagrami rasipanja FI3-BCS Hrvatska sa zemljama eurozone (pojedinačno)

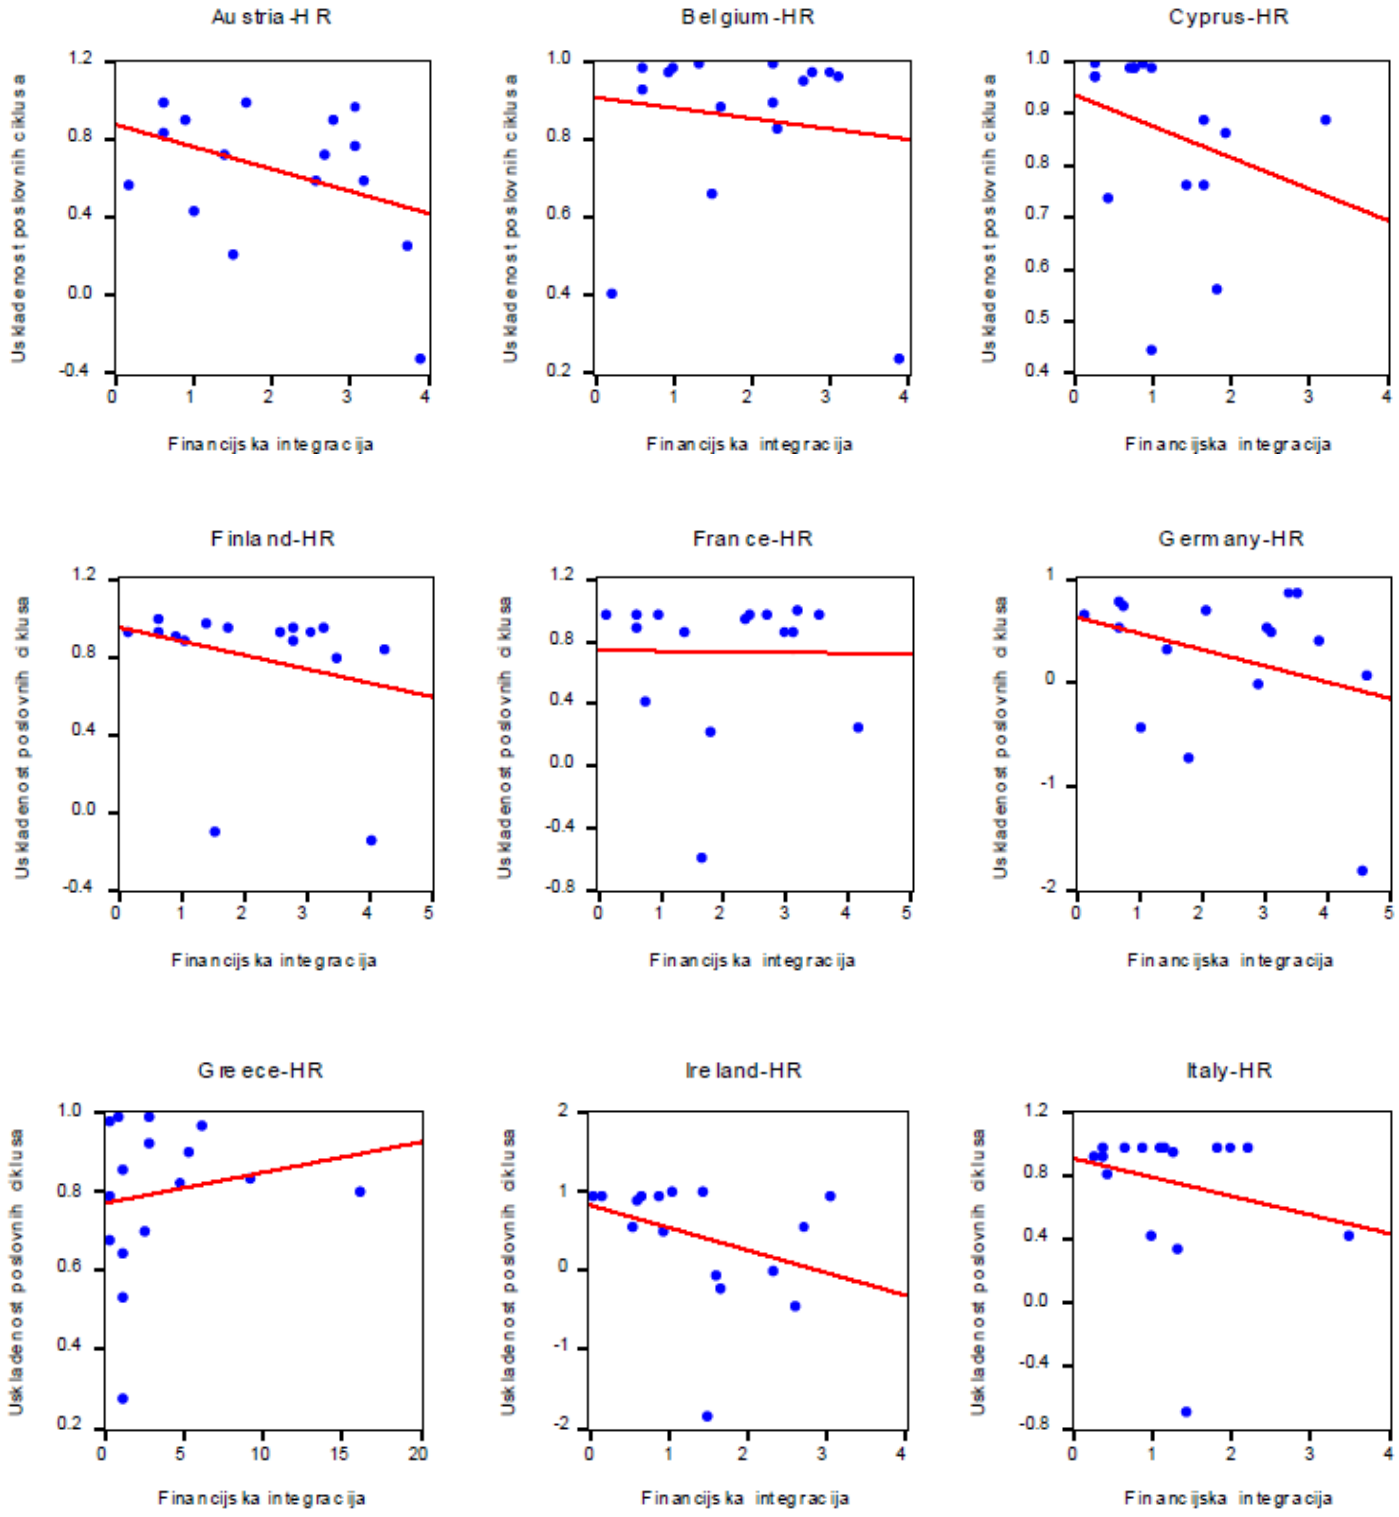

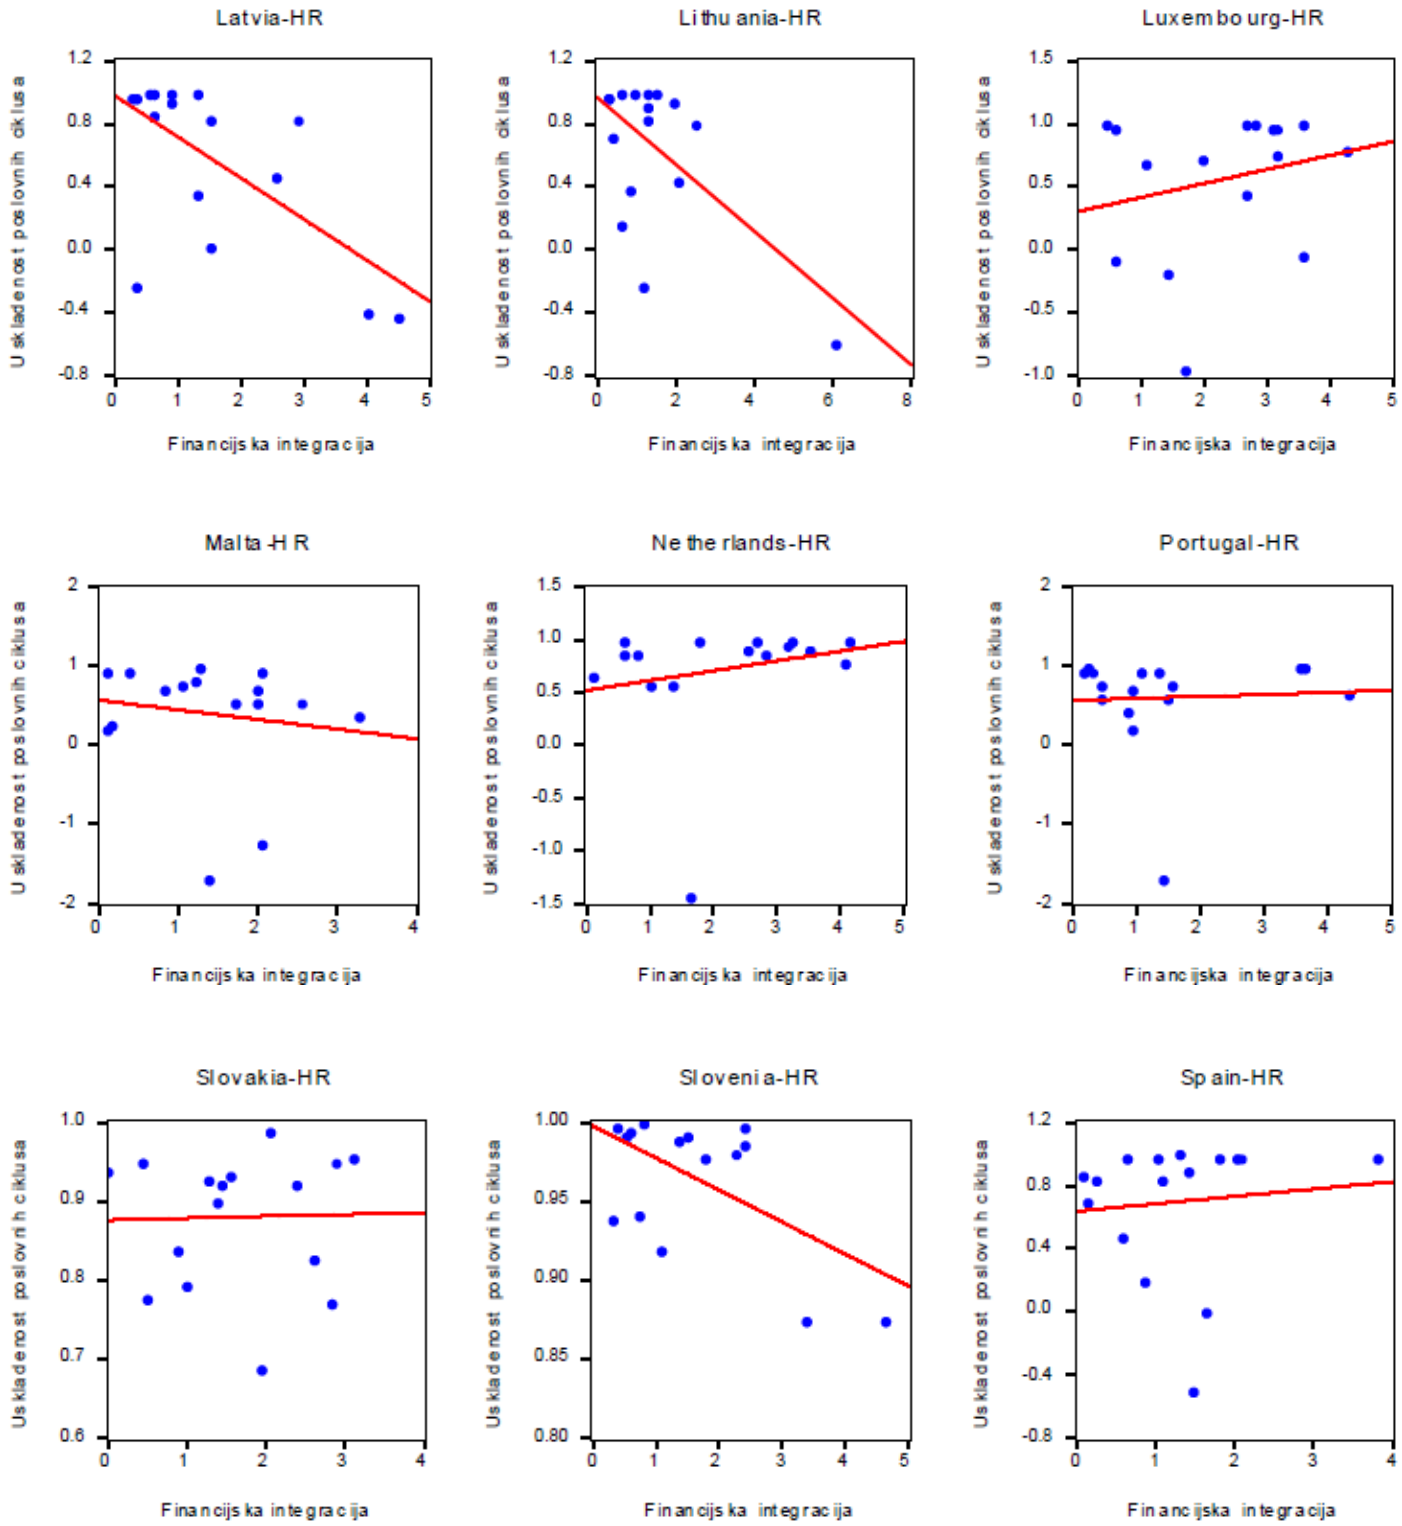

Izvor: Izrada autora (EViews 9)

ŽIVOTOPIS

OSOBNE INFORMACIJE

Tolj Ante

Antuna Branka Šimića 22, 21000 Split (Hrvatska)

091 4545 899

ante.tolj1306@gmail.com

Spol Muško | Datum rođenja 13/06/1985 | Državljanstvo hrvatsko

RADNO ISKUSTVO

09/2011–danas

Osnovna škola Primorski Dolac
Vržine 185, 21227 Primorski Dolac (Hrvatska)

Voditelj računovodstva

Djelatnost ili sektor Odgoj I Obrazovanje

OBRAZOVANJE I OSPOSOBLJAVANJE

2016–2019

dr. sc.

Sveučilište u Splitu, Ekonomski fakultet, Split (Hrvatska)

Poslijediplomski sveučilišni studij Ekonomije i poslovne ekonomije

Polje: Ekonomija

Grana: Financije

Naslov disertacije: Utjecaj financijske integracije na usklađivanje poslovnog ciklusa Hrvatske sa zemljama eurozone

2011–2014

univ. spec. oec.

Sveučilište u Splitu, Ekonomski fakultet, Split (Hrvatska)

Poslijediplomski specijalistički studij Poslovne ekonomije

Smjer: Financijski menadžment

2003–2010

dipl. oec.

Sveučilište u Splitu , Ekonomski fakultet, Split (Hrvatska)

Sveučilišni dodiplomski studij ekonomije

Smjer: Poslovna ekonomija

Usmjerenje: Financije

1999–2003

Prirodoslovno-matematička gimnazija (III. gimnazija), Split (Hrvatska)

OSOBNE VJEŠTINE

Materinski jezik hrvatski

Strani jezici

	RAZUMIJEVANJE		GOVOR		PISANJE
	Slušanje	Čitanje	Govorna interakcija	Govorna produkcija	
engleski	C1	C1	B2	B2	B2

Stupnjevi: A1 i A2: Početnik - B1 i B2: Samostalni korisnik - C1 i C2: Iskusni korisnik
Zajednički europski referentni okvir za jezike

Komunikacijske vještine Timski duh; dobre komunikacijske vještine zahvaljujući radnom iskustvu na radnom mjestu voditelja računovodstva

Organizacijske / rukovoditeljske vještine Dobre organizacijske / rukovoditeljske vještine koordinacije i upravljanja ljudima, projektima i proračunima stečene na radnom mjestu

Poslovne vještine Vještine stručnog vođenja u proračunskom računovodstvu

Vozačka dozvola B

DODATNE INFORMACIJE

Objavljeni znanstveni radovi Pečarić, M. and Tolj, A. (2018). The impact of fiscal policy convergence on business cycle synchronization between Croatia and eurozone countries - panel analysis. Croatian Operational Research Review, 9(2), 281-291.

Priznanja i nagrade Dekanova nagrada za izniman uspjeh postignut na poslijediplomskom sveučilišnom studiju Ekonomije i Poslovne ekonomije, 2019.