HRVATSKA NARODNA BANKA

Istraživanja I-51

Usklađenost poslovnih ciklusa i ekonomskih šokova između Hrvatske i država europodručja

Karlo Kotarac, Davor Kunovac i Rafael Ravnik

Zagreb, listopad 2017.

HNB

ISTRAŽIVANJA I-51

IZDAVAČ
Hrvatska narodna banka
Direkcija za izdavačku djelatnost
Trg hrvatskih velikana 3, 10000 Zagreb
Telefon centrale: 01/4564-555
Telefon: 01/4565-006
Telefaks: 01/4564-687

WEB-ADRESA
www.hnb.hr

GLAVNI UREDNIK
Ljubinko Jankov

UREDNIŠTVO
Vedran Šošić
Gordi Sušić
Davor Kunovac
Tomislav Ridzak
Evan Kraft
Maroje Lang

UREDNICA
Romana Sinković

LEKTORICA
Antonija Vidović

DIZAJNER
Vjekoslav Gjergja

GRAFIČKI UREDNIK
Božidar Bengez

Za stajališta iznesena u ovom radu odgovorni su autori i ta stajališta nisu nužno istovjetna službenim stajalištima Hrvatske narodne banke.
Molimo korisnike ove publikacije da pri korištenju podataka obvezno navedu izvor.
Sve eventualno potrebne korekcije bit će unesene u web-verziju.

ISSN 1334-0077 (online)

HNB

HRVATSKA NARODNA BANKA

ISTRAŽIVANJA I-51

Usklađenost poslovnih ciklusa i ekonomskih šokova između Hrvatske i država europodručja

Karlo Kotarac, Davor Kunovac i Rafael Ravnik

Zagreb, listopad 2017.

Sažetak

U radu smo analizirali usklađenost poslovnih ciklusa te šokova ponude i potražnje Hrvatske i zemalja jezgre europodručja. Dobiveni rezultati upućuju na nekoliko osnovnih zaključaka. Prvo, usklađenost poslovnih ciklusa te korelacija šokova ponude i potražnje između Hrvatske i zemalja jezgre europodručja relativno je visoka. Drugo, simetrični (zajednički) šokovi dominantni su za objašnjavanje dinamike domaćeg BDP-a, dok su doprinosi asimetričnih šokova znatno manji. Treće, rezultati upućuju na konvergenciju šokova ponude i potražnje te poslovnih ciklusa između Hrvatske i zemalja jezgre europodručja. Iz svega navedenog možemo zaključiti kako uvođenje eura i s time povezano prihvaćanje zajedničke protucikličke monetarne politike ne bi trebali biti značajan trošak za hrvatsku ekonomiju.

Ključne riječi:
usklađenost ciklusa, šokovi agregatne ponude i potražnje, simetrični i asimetrični šokovi

JEL klasifikacija:
F33, F44, E42, C32

Sadržaj

Sažetak v

1. Uvod 1

2. Usklađenost poslovnih ciklusa 3
   2.1. Metodologija 3
   2.2. Podaci 5
   2.3. Rezultati 5

3. Usklađenost šokova 9
   3.1. Korelacija agregatnih šokova ponude i potražnje 9
   3.2. Važnost simetričnih i asimetričnih šokova za domaći BDP 13

4. Zaključak 17

Literatura 18

A Dodatak 21
   A1. Alternativna mjera pomične korelacije ciklusa 21
   A2. Slike i tablice 22

1. Uvod

Formiranje ekonomske i monetarne unije (EMU) 90-ih godina prošlog stoljeća izazvalo je ponovni interes ekonomista za *teoriju optimalnih valutnih područja* (engl. *Optimal Currency Area* – OCA) čiji su temelji dani u Mundell (1961.), McKinnon (1963.) i Kenen (1969.). Republika Hrvatska pristupanjem Europskoj uniji obvezala se prihvatiti euro kao službenu valutu i stoga je teorija optimalnih valutnih područja u recentnom razdoblju dospjela i u fokus domaće ekonomske i političke javnosti. Pojednostavnjeno, OCA teorija detaljno razrađuje ideju kako, u slučaju da su troškovi prilagodbe zbog makroekonomskih šokova putem prilagodbe plaća i cijena te mobilnosti rada i kapitala manji od troškova prilagodbe kanalom deviznog tečaja, vjerojatno nema potrebe da navedena država ima vlastitu valutu.

Troškovi ulaska u monetarnu uniju za nove zemlje članice ponajprije se očituju u prihvaćanju zajedničke protucikličke monetarne politike. Osnovna OCA teorija tako postulira kako će navedeni troškovi biti zanemarivi ako su poslovni ciklusi zemalja unutar monetarne unije usklađeni – protucikličko djelovanje zajedničke monetarne politike tada odgovara svim članicama unije (*one-size-fits-all* monetarna politika). Primjerice, ulaskom u monetarnu uniju Hrvatska bi se svjesno odrekla mogućnosti reakcije na asimetrične šokove korištenjem uobičajenih mjera monetarne politike i deviznog tečaja. S druge strane, zajednička monetarna politika reagira jedino na šokove koji su relevantni za cijelu uniju. Iz tog je razloga stupanj usklađenosti hrvatskog ciklusa (i šokova) s ciklusima (i šokovima) europodručja izravno povezan s potencijalnim troškovima pristupanja Hrvatske monetarnoj uniji. U slučaju visoke sinkroniziranosti poslovnih ciklusa Hrvatske i europodručja protuciklička monetarna politika Europske središnje banke (ESB) uspješno bi izglađivala hrvatski poslovni ciklus te gubitak vlastite monetarne politike u tom kontekstu ne bi bio značajan trošak za domaću ekonomiju.

OCA teorija također analizira opravdanost zadržavanja vlastite valute s aspekta utjecaja šokova na ekonomsku aktivnost potencijalnih članica monetarne unije. Teorija postulira kako se pojedinoj zemlji isplati zadržati vlastitu valutu u slučaju da je BDP navedene zemlje pod dominantnim utjecajem *asimetričnih šokova*. Drugim riječima, ako ekonomski šokovi na različit način djeluju na analiziranu domaću ekonomiju u odnosu na ekonomije članica monetarne unije, potrebna je prilagodba bilateralnog tečaja kako bi se apsorbirali navedeni šokovi. Primjerice, ako je hrvatski BDP pod dominantnim utjecajem šokova koji na domaći BDP utječu uz suprotan predznak u odnosu na BDP europodručja, potrebna je prilagodba tečaja kune prema euru kako bi domaća ekonomija na adekvatan način apsorbirala takve šokove. Ako je, s druge strane, BDP domaće ekonomije pod dominantnim utjecajem *simetričnih šokova*, odnosno ako ekonomski šokovi na sličan način djeluju na domaću ekonomiju i ekonomiju monetarne unije, potrebna prilagodba deviznog tečaja zbog ekonomskih šokova bila bi jednaka za sve zemlje. Drugim riječima, u tom bi slučaju prilagodba kroz kanal deviznog tečaja djelovala putem prilagodbe tečaja prema trećim zemljama koje nisu članice monetarne unije. Posjedovanje vlastite valute tada nije komparativna prednost zemlje s aspekta apsorpcije šokova i trošak vezan uz gubitak vlastite valute stoga bi bio zanemariv.

Osnovni je cilj rada detaljno analizirati u kojoj su mjeri šokovi ponude i potražnje te poslovni ciklusi u Hrvatskoj usklađeni s onima u europodručju. Osim toga, kako bismo detaljnije ispitali troškove povezane s prihvaćanjem zajedničke europske valute, istražujemo u kojoj je mjeri hrvatski BDP pod utjecajem *simetričnih* (zajedničkih) i *asimetričnih* šokova. Svrha rada stoga *nije* analizirati sve troškove i koristi povezane s uvođenjem eura kao službene valute,[1] već je naglasak isključivo na trošku vezanom uz prihvaćanje zajedničke protucikličke monetarne politike.

Analiza je provedena u dva koraka. U prvom koraku istražujemo u kojoj su mjeri *poslovni ciklusi* Hrvatske i zemalja jezgre europodručja međusobno usklađeni. Kako bismo dobivene rezultate za Hrvatsku stavili u širi kontekst, usklađenost Hrvatske s europodručjem uspoređujemo s rezultatima za rubne zemlje EU-a. Analiza usklađenosti ciklusa, osim na korelacijama, zasniva se i na dvije dodatne mjere: *faznoj sinkroniziranosti* i *sličnosti* ciklusa, pri čemu fazna sinkroniziranost mjeri usklađenost predznaka ciklusa, dok sličnost mjeri usklađenost amplituda ciklusa (vidi Mink *et al.*, 2012.). Bitan nalaz ovog dijela analize jest taj da je usklađenost poslovnih ciklusa Hrvatske i jezgre europodručja relativno visoka i općenito je nešto veća u usporedbi s ostalim rubnim zemljama EU-a.

U drugom koraku analiziramo u kojoj su mjeri *šokovi agregatne ponude i potražnje* koji generiraju ciklus Hrvatske slični šokovima zemalja jezgre europodručja. Slično kao i u prethodnom koraku, analize rezultate za Hrvatsku uspoređujemo s onima za rubne zemlje EU-a. Navedene šokove za svaku zemlju, u skladu sa srodnom literaturom, identificiramo iz šokova jednostavnih bivarijatnih VAR modela (Bayoumi i Eichengreen, 1992., 1993. i 1994.). Usklađenost tako dobivenih šokova ponude i potražnje Hrvatske i zemalja jezgre europodručja zatim analiziramo pomoću koeficijenata korelacije. Nakon identifikacije šokova pomoću simplificiranoga bivarijatnog VAR-a, odmičemo se od ovoga standardnog modela i konstruiramo bogatiji VAR model kojim identificiramo šest šokova. To nam omogućuje detaljniju analizu mehanizama koji generiraju domaći i strani ciklus i tako izravno odgovaramo na ključno pitanje o isplativosti odricanja vlastite monetarne politike u kontekstu pristupanja monetarnoj uniji – u kojoj je mjeri hrvatski BDP pod utjecajem simetričnih i asimetričnih šokova? Kao mjera relativne važnosti simetričnih šokova za domaću ekonomiju koristi se doprinos svih simetričnih šokova koji su izračunati iz povijesne dekompozicije BDP-a. Dobiveni rezultati upućuju na sljedeće osnovne zaključke. Prvo, usklađenost šokova potražnje između Hrvatske i jezgre europodručja relativno je visoka te je nešto veća u usporedbi s ostalim rubnim zemljama. S druge strane, korelacija šokova ponude u Hrvatskoj i zemljama jezgre europodručja nešto je manja. Drugo, simetrični šokovi ponude i potražnje izrazito su značajni za hrvatski BDP, dok su doprinosi asimetričnih šokova znatno manji. Treće, važnost simetričnih šokova za hrvatski BDP raste u razdoblju nakon 2006. godine. S tim u vezi, valja naglasiti kako teorija o endogenosti OCA (Frankel i Rose, 1998.) postulira kako bi se navedeni proces sinkronizacije šokova i ciklusa mogao dodatno ubrzati ulaskom u monetarnu uniju. Iz svega navedenog možemo zaključiti kako uvođenje eura ne bi trebalo biti značajan trošak za hrvatsku ekonomiju s aspekta protucikličkog djelovanja monetarne politike.

Usklađenost ciklusa te šokova ponude i potražnje između Hrvatske i europodručja već je bila predmet ranijih istraživanja. Autori su prvih relevantnih istraživanja Šonje i Vrbanc (2000.) te Belullo, Šonje i Vrbanc (2000.), a u njima je istražena usklađenost ciklusa nezaposlenosti Hrvatske i ostalih zemalja Jugoistočne Europe s njemačkim ciklusom nezaposlenosti. Autori nalaze usku povezanost hrvatskog i njemačkog ciklusa u razdoblju 1992. – 1999. Zatim, Arčabić (2011.) računa jednostavne koeficijente korelacije cikličke komponente BDP-a Hrvatske i odabranih zemalja EMU-a. Rezultati navedenog rada sugeriraju kako je usklađenost ciklusa nakon 2002. godine relativno visoka te kako hrvatski ciklus vremenski ne zaostaje za ciklusom zemalja EMU-a. Slični rezultati dobiveni su u Obradović i Mihajlović (2013.) te Hildebrandt i Moder (2015.). Autori su prvog rada u kojem je analizirana koreliranost šokova agregatne ponude i potražnje između Hrvatske i

1 Osim troškova povezanih s gubitkom autonomnog vođenja protucikličke monetarne politike, postoje i ostali potencijalni troškovi glede uvođenja eura, kao što su primjerice stvaranje makroekonomskih neravnoteža zbog prekomjernog priljeva kapitala, porast razine cijena zbog konverzije valute, jednokratni troškovi konverzije i jednokratni troškovi pristupanja HNB-a Eurosustavu te troškovi sudjelovanja u pružanju financijske pomoći drugim državama članicama. Što se tiče koristi od uvođenja eura kao službene valute, ističemo sljedeće: uklanjanje valutnog rizika u gospodarstvu, smanjenje troška zaduživanja domaćih sektora te smanjenje rizika od izbijanja bankovne i valutne krize. Nadalje, uvođenje eura donosi niže transakcijske troškove te može dati poticaj vanjskotrgovinskoj razmjeni. Konačno, članstvom u monetarnoj uniji Hrvatska dobiva pristup mehanizmima financijske pomoći europodručja, a HNB sudjeluje u raspodjeli monetarnog prihoda Eurosustava.

zemalja EMU-a Fidrmuc i Korhonen (2002.) korištenjem standardne identifikacije iz Eichenbaum i Bayoumi (1992.). Dobiveni rezultati sugeriraju kako u 90-im godinama šokovi potražnje u Hrvatskoj nisu bili korelirani sa šokovima potražnje u zemljama EMU-a, dok su šokovi ponude pokazivali umjerenu korelaciju u usporedbi s drugim posttranzicijskim zemljama. Broz (2010.) koristi se sličnom metodologijom na uzorku od 1995. do 2006. i potvrđuje navedene rezultate. Velickovski (2013.) pronalazi sličnu korelaciju za šokove ponude, ali i znatno snažniju korelaciju šokova potražnje. Ovaj je rad također usko vezan uz literaturu koja pomoću VAR modela upućuje na važnost stranih šokova za kretanja ključnih varijabla domaće ekonomije kao što su primjerice Jankov *et al.* (2008.), Krznar i Kunovac (2010.), Jovančević *et al.* (2012.), Dumičić *et al.* (2015.) te Jovičić i Kunovac (2017.).

Rad ima nekoliko originalnih doprinosa literaturi – onoj koja se fokusira na usklađenost ciklusa Hrvatske i stranog ciklusa, ali i općenitijoj literaturi o optimalnim valutnim područjima. Prije svega, rad unapređuje postojeću metodologiju kvantifikacije doprinosa simetričnih i asimetričnih šokova za kretanje BDP-a članica i potencijalnih članica monetarne unije (Bayoumi i Eichengreen (1992.), Peersman (2011.) i slični radovi). Zatim, u kontekstu domaće literature, ovo je prvi rad prema saznanjima autora koji, osim analize korelacije ciklusa Hrvatske i zemalja EMU-a, analizira i druge mjere usklađenosti ciklusa – sinkroniziranost i sličnost ciklusa. Konačno, rad obuhvaća i recentno razdoblje nakon pristupanja Hrvatske Europskoj uniji koje uključuje značajne strukturne i institucionalne promjene te je očekivano da su se navedene promjene odrazile i na usklađenost ciklusa. Nakon uvodnog dijela rada, u drugom se poglavlju analizira usklađenost poslovnih ciklusa između europodručja i Hrvatske, kao i između ostalih rubnih članica EU-a, dok se treće poglavlje bavi analizom usklađenosti njihovih šokova. Posljednje poglavlje donosi zaključke.

2. Usklađenost poslovnih ciklusa

Postojeća empirijska literatura o usklađenosti poslovnih ciklusa uvelike se oslanja na izračun korelacija među ciklusima pojedinih zemalja. Ipak, treba imati na umu kako je na temelju korelacije ciklusa ponekad vrlo teško dati ocjenu njihove usklađenosti koja bi bila korisna nositeljima zajedničke monetarne politike u monetarnoj uniji (Mink *et al.*, 2012., Belke *et al.*, 2017.). Primjerice, poslovni ciklusi dviju zemalja mogu u promatranom razdoblju biti u istim fazama – u zajedničkim recesijama ili ekspanzijama, a istovremeno imati vrlo nizak koeficijent korelacije. S druge strane, ciklusi dviju zemalja mogu biti savršeno korelirani, pri čemu im amplitude uopće ne moraju biti slične. Stoga u ovom radu, osim pomoću korelacija, usklađenost ciklusa Hrvatske i zemalja europodručja analiziramo pomoću dodatne dvije mjere – *fazne sinkroniziranosti ciklusa i sličnosti ciklusa*. Fazna sinkroniziranost mjeri usklađenost predznaka ciklusa, dok sličnost mjeri usklađenost amplituda ciklusa. Sve tri navedene mjere izračunate su za Hrvatsku u odnosu na zemlje jezgre europodručja te smo rezultate za Hrvatsku usporedili s rezultatima za ostale rubne zemlje EU-a. U svrhu lakše analize i vizualizacije, usklađenost ciklusa svih analiziranih zemalja prikazana je u dvodimenzionalnom prostoru primjenom metode višedimenzionalnog skaliranja. Navedena metoda omogućuje konzistentno prikazivanje svih bilateralnih usklađenosti ciklusa na jednom grafu. U nastavku su ukratko opisane korištene mjere usklađenosti ciklusa (prema Mink *et al.*, 2012.) kao i metoda višedimenzionalnog skaliranja.

2.1. Metodologija

Pretpostavimo da želimo usporediti ciklus neke države s ciklusima svih država iz nekog skupa referentnih država. Analiziranu državu označit ćemo s i, a referentne države neka su indeksirane s $r = 1,...,n$.

Fazna sinkroniziranost ciklusa. Za državu i i svaku referentnu zemlju r računamo mjeru sinkroniziranosti $\varphi_{ir}(t)$ koja indicira je li u trenutku t predznak ciklusa zemlje i, $c_i(t)$ jednak predznaku ciklusa referentne zemlje $c_r(t)$:

$$\varphi_{ir}(t)=\frac{c_i(t)c_r(t)}{|c_i(t)c_r(t)|}=\begin{cases}1, & \text{ako ciklus zemlje } i \text{ ima jednak predznak kao ciklus zemlje } r\\ -1, & \text{ako ciklus zemlje } i \text{ ima različit predznak od ciklusa zemlje } r\end{cases} \tag{1}$$

Za svako razdoblje t zatim je izračunata ukupna fazna sinkroniziranost ciklusa analizirane zemlje s ciklusima grupe od n zemalja:

$$\varphi_i(t)=\sum_{r=1}^{n} w_r\cdot\varphi_{ir}(t). \tag{2}$$

Navedena mjera predstavlja ponderirani prosjek n bilateralnih faznih sinkroniziranosti ciklusa referentnih država s ciklusom analizirane zemlje izračunatih izrazom (1). Ako su u određenom trenutku ciklusi svih n zemalja imali isti predznak kao ciklus analizirane zemlje i, $\varphi_i(t)$ bit će jednak 1. Ponderi w_r moraju biti nenegativni te im suma mora biti jednaka 1.

Sličnost ciklusa. Sličnost ciklusa mjeri usklađenost amplituda dvaju ciklusa. Za odabranu zemlju i i svaku državu iz skupa referentnih država (indeksiranu s $r=1,...,n$) računamo prikazanu mjeru sličnosti ciklusa za svaki trenutak t:

$$\gamma_{ir}(t)=1-\frac{|c_i(t)-c_r(t)|}{\sum_{r=1}^{n}|c_r(t)|/n}. \tag{3}$$

Za prikazanu mjeru vrijedi da je $\gamma_{ir}(t)\leq 1$ te ako su u određenom trenutku t obje zemlje imale identičan ciklus, $\gamma_{ir}(t)$ će biti jednak 1. Ukupna sličnost ciklusa analizirane zemlje s ciklusima skupine od n zemalja izračunata je, slično kao i za mjeru fazne sinkroniziranosti, sljedećim izrazom:

$$\gamma_i(t)=\sum_{r=1}^{n} w_r\cdot\gamma_{ir}(t). \tag{4}$$

U ovom radu Hrvatska odnosno ostale rubne europske zemlje jesu analizirane zemlje, dok referentna grupa od n zemalja obuhvaća zemlje jezgre europodručja. Ponderi w_r u izrazima (2) i (4) jesu udjeli BDP-a svake od zemalja jezgre u BDP-u europodručja. Ukupna fazna sinkroniziranost za svaku analiziranu zemlju stoga se interpretira kao sinkroniziranost ciklusa navedene zemlje s ciklusom europodručja. Slično se interpretira i ukupna sličnost ciklusa za svaku analiziranu zemlju.

Metoda višedimenzionalnog skaliranja (engl. *multidimensional scaling*) podrazumijeva način kako od poznatih bilateralnih udaljenosti n objekata doći do prikaza tih objekata u, najčešće, dvodimenzionalnom koordinatnom sustavu (vidi Torgerson, 1952.). Preciznije, metoda kao ulaz zahtijeva kvadratnu matricu D koja mora biti simetrična ($d_{ij}=d_{ji}$), imati nenegativne elemente ($d_{ij}\geq 0$) te imati nule na glavnoj dijagonali ($d_{ii}=0$). Element d_{ij} ove matrice predstavlja udaljenost između i-tog i j-tog objekta. Cilj je metode pomoću matrice D naći točke $x_1,x_2,...,x_n$ u q-dimenzionalnom realnom prostoru $\mathbb{R}^q$ (najčešće $\mathbb{R}^2$) za koje je d_{ij} približno jednako euklidskoj udaljenosti točaka x_i i x_j. Uz dodatnu pretpostavku da vrijedi $\sum_{k=1}^{n} x_k=0$, rješenje ovog problema je jedinstveno (vidi Wickelmaier, 2003.) i nalazi se sljedećim postupkom:

1. Izračuna se matrica $B=-\frac{1}{2}JD^{(2)}J$, gdje je $D^{(2)}=[d_{ij}^2]$, a $J=I_n-\frac{1}{n}\mathbf{1}_n$. Ovdje je I_n jedinična matrica, a $\mathbf{1}_n$ kvadratna matrica reda n čiji su svi elementi 1.
2. Odredi se dekompozicija simetrične matrice B na svojstvene vrijednosti $\lambda_1,...\lambda_n$ (pri čemu je $\lambda_1\geq\lambda_2\geq\cdots\geq\lambda_n$) i pripadajuće ortogonalne svojstvene vektore $v_1,...,v_n$.
3. Za odabranu dimenziju q traženi $X=[x_1x_2...x_n]'$ dobije se prema formuli

$$X=[v_1...v_q]\cdot diag(\sqrt{\lambda_1},...,\sqrt{\lambda_q}). \tag{5}$$

Ako je $q=2$, tada se vektori $x_1, x_2, ..., x_n$ obično prikazuju grafički u koordinatnoj ravnini. Udaljenosti pojedinih objekata na ovom grafu u najvećoj bi mogućoj mjeri trebale poštivati udaljenosti iz matrice D. Bitno je napomenuti da proizvoljna rotacija svih točaka oko ishodišta predstavlja istu konfiguraciju, odnosno vrijednosti na osima ne daju nikakvu informaciju – bitan je jedino relativni položaj točaka na grafu. U našoj analizi objekti

na koje ćemo primijeniti metodu višedimenzionalnog skaliranja bit će poslovni ciklusi države. U prvom koraku konstruiramo matricu A koja može sadržavati podatke o faznoj sinkroniziranosti ciklusa, sličnosti ciklusa ili pak predstavljati korelacijsku matricu. U svakom od ovih slučajeva matrica A je simetrična, za njene elemente a_{ij} vrijedi da je $a_{ij} \leq 1$ te ima svojstvo da veće vrijednosti elementa a_{ij} znače veću sličnost između države i i države j. U drugom koraku definiramo matricu D čiji su elementi $d_{ij} = 1 - a_{ij}$ te na njoj primjenjujemo opisani postupak.

2.2. Podaci

Ciklusi ekonomske aktivnosti izolirani su iz serija realnog BDP-a 24 zemlje EU-a[2] primjenom jednostavnoga univarijatnog HP filtra, uz korištenje koeficijenta λ od 1600. Korišten je sezonski prilagođeni ulančani BDP u stalnim cijenama s Eurostata u domaćoj valuti, referentna godina 2010. Dužina uzorka razlikuje se po zemljama ovisno o dostupnosti podataka, no najkraći uzorak uključen u analizu odnosi se na razdoblje od prvog tromjesečja 1998. do trećeg tromjesečja 2016.[3] Poznato je kako HP filtar pripada skupini dvostranih univarijatnih filtara, zbog čega se pouzdanost procjena trenda varijabla smanjuje pri samom kraju analiziranog uzorka na način da je filtrirani trend pristran prema ostvarenjima serije na nekoliko zadnjih opažanja (tzv. *end-point* problem). Kako bismo na adekvatan način razriješili navedeni problem, vremenske serije realiziranog BDP-a produžene su prognozama za razdoblje od četvrtog tromjesečja 2016. do četvrtog tromjesečja 2018. U tu svrhu korištene su, ovisno o raspoloživosti, prognoze *Consensus Economic Forecasta* i Europske komisije. Za one zemlje za koje nisu dostupne prognoze na tromjesečnoj razini, interpolirane su godišnje stope na četvrtgodišnju frekvenciju.

Navedene 24 zemlje članice EU-a podijelili smo u dvije skupine. Prvu skupinu čini sedam zemalja *jezgre europodručja* koje čine oko 90% BDP-a europodručja. U navedenu skupinu uključene su sljedeće zemlje: Njemačka, Francuska, Italija, Španjolska, Nizozemska, Belgija i Austrija. Drugu skupinu zemalja čine *rubne zemlje EU-a* za koje će se računati ranije opisane mjere fazne sinkroniziranosti i sličnosti, pri čemu će ponderi u izrazima (2) i (4) biti udjeli BDP-a svake od zemalja jezgre u BDP-u europodručja.[4] Korištena definicija jezgre europodručja odabrana je po kriteriju važnosti za zajedničku monetarnu politiku. Naime, monetarna politika ESB-a, između ostalog, reagira na kretanja poslovnog ciklusa cijelog europodručja te se stoga ciklusi država koje čine oko 90% BDP-a europodručja mogu smatrati relevantnim reprezentantom ciklusa cijele monetarne unije.

2.3. Rezultati

Na Slici 1. prikazane su pomične korelacije među ciklusima Hrvatske i jezgre europodručja (crvena linija) te prosječne pomične korelacije između ciklusa grupe rubnih zemalja EU-a i europodručja (puna plava linija) zajedno s intervalom od jedne standardne devijacije (isprekidana plava linija).[5] Prikazana slika sugerira kako je hrvatski ciklus u razdoblju prije 2006. godine bio negativno koreliran s ciklusom europodručja, dok neposredno prije globalne financijske krize navedena korelacija snažno raste. Zbog zajedničke kontrakcije ekonomske aktivnosti korelacija ostaje na razinama iznad 80%. Korelacija se u razdoblju od 2011. postupno

2 Uključene su sve zemlje EU-a osim Malte, Luksemburga, Irske i Cipra, za koje nije dostupna adekvatna vremenska serija realnog BDP-a.

3 Dostupne serije BDP-a za Hrvatsku, Poljsku i Bugarsku produžene su unatrag (za Hrvatsku i Bugarsku za razdoblje od prvog tromjesečja 1998. do četvrtog tromjesečja 1999. te za Poljsku za razdoblje od prvog tromjesečja 1998. do četvrtog tromjesečja 2001.) korištenjem tromjesečne dinamike sezonski prilagođenih serija BDP-a prema metodologiji ESA 95. Ove su serije preuzete iz baze podataka Europske središnje banke.

4 Za drugu smo skupinu zemalja, alternativno, mogli uzeti samo rubne zemlje europodručja, ali zbog potpunosti analize promatrali smo širi skup zemalja koji uključuje i ostale zemlje EU-a (koje nisu dio europodručja). Rezultati su za spomenute dvije verzije podataka gotovo identični. Svi dobiveni rezultati po pojedinim državama dani su u Dodatku rada.

5 U Dodatku rada pojedinačno je prikazana pomična korelacija za cikluse svih analiziranih rubnih zemalja s ciklusima zemalja jezgre. Slika 11. daje usporedbu rezultata za Hrvatsku i rubne zemlje europodručja, odnosno Slika 12. za Hrvatsku i ostale rubne zemlje EU-a koje nisu članice europodručja. U Tablici 3. prikazani su bilateralni koeficijenti korelacije za sve parove zemalja u cjelokupnom razdoblju.

smanjuje. Ako navedene rezultate za Hrvatsku usporedimo s ostalim rubnim zemljama, možemo zaključiti kako su prikazane korelacije u razdoblju od 2006. godine u skladu s prosječnom korelacijom navedenih zemalja.[6] Također je potrebno ukazati na zanimljiv nalaz o raspršenosti među zemljama, odnosno prikazanim standardnim devijacijama. Naime, slika sugerira kako je navedena raspršenost velika u razdobljima ekspanzije odnosno u razdobljima 2002. – 2007. i 2014. – 2016., dok su u razdoblju recesije ciklusi svih europskih zemalja snažno korelirani, što reflektira podložnost istim ekonomskim šokovima tijekom recesije.

Slika 1. Pomične korelacije ciklusa

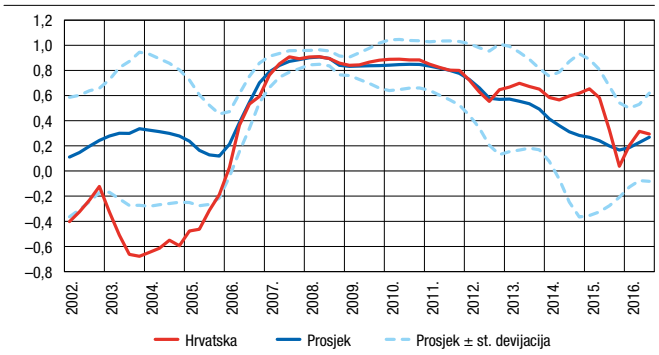

Napomena: Crvenom linijom prikazan je ponderiran prosjek koeficijenta korelacije hrvatskog ciklusa s ciklusima sedam zemalja jezgre europodručja, gdje ponderi čine udio BDP-a svake od tih zemalja u BDP-u europodručja. Isprekidane plave linije označuju interval od jedne standardne devijacije oko prosječne korelacije (puna plava linija) izračunate na skupu ostalih rubnih zemalja. Prikazan koeficijent korelacije izračunat je kao četverogodišnji pomični prosjek.
Izvor: HNB

Slika 2. prikazuje prosječnu faznu sinkroniziranost ciklusa Hrvatske i rubnih zemalja EU-a s ciklusom zemalja jezgre europodručja. Rezultati za razdoblje do 2006. godine u skladu su s rezultatima o koreliranosti ciklusa – u navedenom razdoblju sinkroniziranost hrvatskog ciklusa niža je od prosjeka ostalih zemalja. No, sinkroniziranost domaćega poslovnog ciklusa s ciklusima zemalja jezgre europodručja nakon toga snažno raste i neposredno pred izbijanje financijske krize dostiže gotovo savršenu sinkroniziranost. Zbog zajedničkih

Slika 2. Fazna sinkroniziranost ciklusa

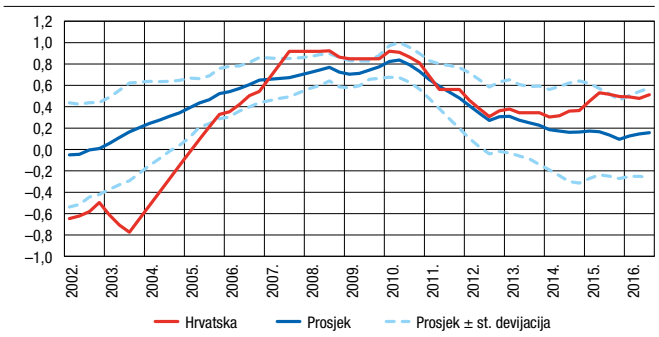

Napomena: Crvenom linijom prikazan je ponderiran prosjek fazne sinkroniziranosti hrvatskog ciklusa s ciklusima sedam zemalja jezgre europodručja, gdje ponderi čine udio BDP-a svake od tih zemalja u BDP-u europodručja. Isprekidane plave linije označuju interval od jedne standardne devijacije oko prosječne sinkroniziranosti (puna plava linija) izračunate na skupu ostalih rubnih zemalja. Prikazana mjera fazne sinkroniziranosti izračunata je kao četverogodišnji pomični prosjek. Fazna sinkroniziranost obuhvaća raspon od –1 (maksimalna nesinkroniziranost) do 1 (maksimalna sinkroniziranost).
Izvor: HNB

6 Navedene rezultate potvrđuje i izračunata alternativna mjera korelacije opisana u Dodatku i prikazana na Slici 17. Naime, navedena slika prikazuje transformirani korelacijski indeks za Hrvatsku i prosječni indeks zajedno s intervalom od jedne standardne devijacije za ostale rubne zemlje EU-a. Navedena slika također sugerira kako je korelacijski indeks za Hrvatsku pri kraju uzorka značajno viši nego na početku. Osim toga, od 2009. godine trend rasta korelacijskog indeksa za Hrvatsku sličan je prosjeku korelacijskog indeksa za ostale zemlje EU-a.

globalnih šokova u razdoblju 2008. – 2009., sinkroniziranost Hrvatske i europodručja ostaje na visokim razinama te za cjelokupno preostalo razdoblje ostaje viša od prosječne sinkroniziranosti rubnih zemalja. Sinkroniziranost ciklusa Hrvatske i europodručja opada isključivo u razdoblju 2011. – 2013., odnosno za vrijeme krize javnih financija u europodručju. Slika također jasno sugerira kako je pri samom kraju uzorka hrvatski ciklus značajno sinkroniziraniji u odnosu na prosjek rubnih zemalja EU-a čija sinkroniziranost nastavlja opadati. Štoviše, detaljnija analiza upućuje na to da je sinkroniziranost hrvatskog ciklusa s ciklusom zemalja jezgre na samom kraju uzorka veća od svih sinkroniziranosti analiziranih rubnih zemalja europodručja (Slika 13. u Dodatku rada). Navedeni nalaz vezan uz kraj uzorka potvrđuje ranije iznesene tvrdnje kako fazna sinkroniziranost i koeficijent korelacije mogu u određenim razdobljima upućivati na suprotne zaključke.

Slika 3. na ekvivalentan način prikazuje rezultate sličnosti ciklusa.[7] Navedena mjera za razdoblje do 2010. godine dodatno potvrđuje ranije iznesene nalaze. Naime, sličnost ciklusa Hrvatske i zemalja jezgre europodručja raste u razdoblju neposredno prije i tijekom globalne recesije, no zatim 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.

Slika 3. Sličnost ciklusa

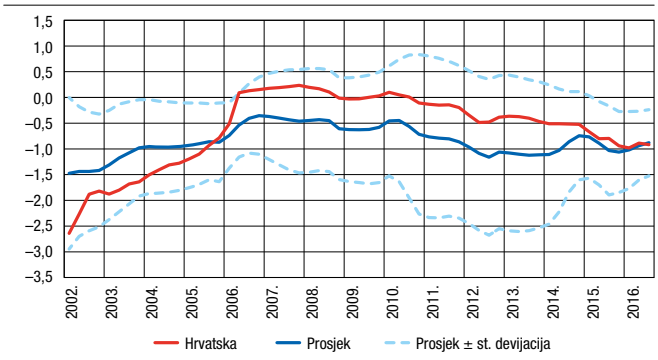

Napomena: Crvenom linijom prikazan je ponderiran prosjek sličnosti hrvatskog ciklusa s ciklusima sedam zemalja jezgre europodručja, gdje ponderi čine udio BDP-a svake od tih zemalja u BDP-u europodručja. Isprekidane plave linije označuju interval od jedne standardne devijacije oko prosječne sličnosti ciklusa (puna plava linija) izračunate na skupu ostalih rubnih zemalja. Prikazana mjera sličnosti izračunata je kao četverogodišnji pomični prosjek. Sličnost obuhvaća raspon od −∞ do 1 (jednake amplitude ciklusa).
Izvor: HNB

Slika 4. ilustrira udaljenost država pomoću mjera sinkroniziranosti i sličnosti ciklusa za sve parove zemalja na temelju rezultata višedimenzionalnog skaliranja. Kako bismo istražili u kojoj se mjeri prikazani rezultati mijenjaju kroz vrijeme, prikazane su mape za tri razdoblja – na ukupnom uzorku (slike (a) i (b)), prvoj (slike (c) i (d)) i drugoj polovici uzorka (slike (e) i (f)). Općenito, udaljenost između dvije zemlje na mapi trebala bi opadati s porastom sinkroniziranosti/sličnosti među pripadajućim ciklusima. Na slikama su prikazane obje skupine zemalja na način da su rubne zemlje označene crvenom, zemlje jezgre europodručja plavom, dok je Hrvatska posebno istaknuta zelenom bojom. Rezultati izračunati na ukupnom uzorku za obje mjere upućuju na relativno slabu usklađenost ciklusa Hrvatske i jezgre europodručja (relativno velike udaljenosti). No slike 4. (e) i (f) jasno pokazuju kako se u drugoj polovici uzorka (nakon 2006. godine) hrvatski ciklus značajno približio ciklusima gotovo svih zemalja jezgre europodručja, što potvrđuje ranije iznesene nalaze. Naime, u navedenom je razdoblju hrvatski ciklus uvelike sinkroniziran s ciklusima Nizozemske, Belgije, Njemačke i Italije. Što se rubnih zemalja tiče, hrvatski ciklus nalazi se u blizini češkog, slovenskog, slovačkog, bugarskog i švedskog ciklusa. Slika 4. (f) sugerira kako su rezultati za sličnost ciklusa uglavnom u skladu s rezultatima za sinkroniziranost, uz nešto veću relativnu udaljenost od Njemačke i Italije.

7 U Dodatku rada pojedinačno je prikazana sličnost ciklusa svih analiziranih rubnih zemalja s ciklusima zemalja jezgre. Slika 15. daje usporedbu rezultata za Hrvatsku i rubne zemlje europodručja, odnosno Slika 16. za Hrvatsku i ostale rubne zemlje EU-a koje nisu članice europodručja. Tablica 5. prikazuje bilateralne sličnosti za sve parove zemalja.

Slika 4. Rezultat višedimenzionalnog skaliranja na temelju fazne sinkroniziranosti i sličnosti ciklusa

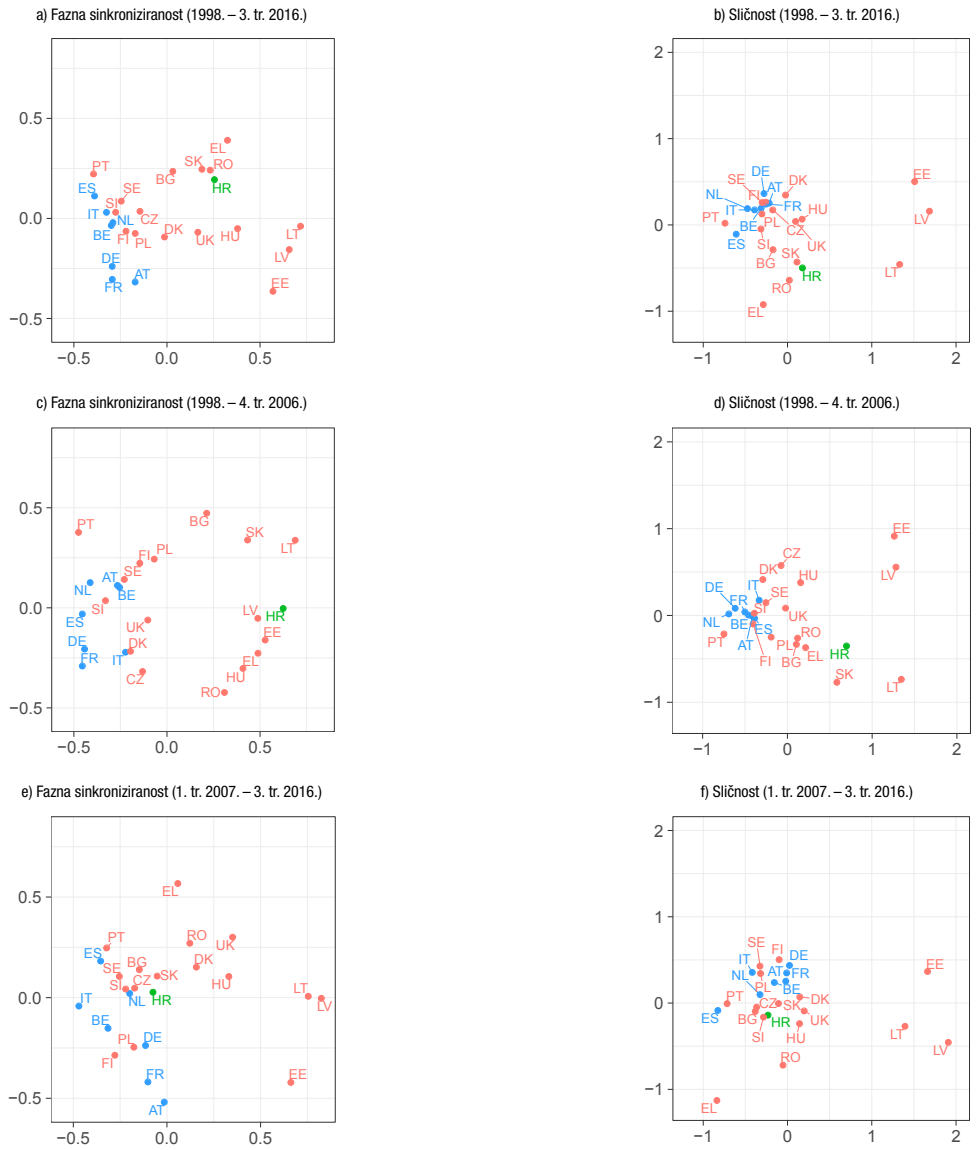

Izvor: HNB

Iz svih prikazanih rezultata možemo zaključiti kako je usklađenost poslovnih ciklusa Hrvatske s onima zemalja jezgre europodručja relativno visoka. Navedena usklađenost za Hrvatsku, izračunata na temelju svih triju mjera, nešto je veća u usporedbi s ostalim rubnim zemljama EU-a. Također, rezultati sugeriraju kako usklađenost ciklusa između Hrvatske i europodručja raste neposredno prije globalne financijske krize te, ovisno o promatranoj mjeri, ostaje na relativno visokim razinama. Kako bismo dodatno provjerili nalaze prikazane u ovom poglavlju, u nastavku analiziramo usklađenost šokova odnosno transmisije simetričnih i asimetričnih šokova na domaći BDP.

3. Usklađenost šokova

U prethodnom poglavlju analizirana je usklađenost poslovnih ciklusa kao važnoga kriterija za uspješno protucikličko djelovanje zajedničke monetarne politike. No, ključna posljedica pristupanja monetarnoj uniji jest nemogućnost apsorbiranja asimetričnih šokova korištenjem uobičajenih mjera domaće monetarne politike i deviznog tečaja. U kojoj će mjeri navedena ograničenja zaista utjecati na zemlje članice monetarne unije, ovisi ponajprije o vrsti i stupnju usklađenosti šokova, kao i o brzini prilagodbe ekonomije takvim šokovima. Kako bismo to detaljnije istražili, u ovom poglavlju ponajprije analiziramo usklađenost šokova Hrvatske i jezgre europodručja. Osim toga, uzimajući u obzir propagaciju šokova, analiziramo i reakciju domaće ekonomske aktivnosti na simetrične i asimetrične šokove. U prvom potpoglavlju pomoću standardnih bivarijatnih VAR modela identificiramo strukturne šokove za svaku državu te njihovu usklađenost mjerimo standardnim koeficijentima korelacija. Nakon toga, u drugom potpoglavlju korištenjem većeg VAR modela s uključenih šest varijabla, analiziramo važnost doprinosa simetričnih (zajedničkih) i asimetričnih šokova za objašnjavanje dinamike realne aktivnosti u Hrvatskoj.

3.1. Korelacija agregatnih šokova ponude i potražnje

U ovom dijelu rada analiziramo usklađenost šokova agregatne ponude i potražnje između Hrvatske i zemalja jezgre europodručja. Slično kao u prethodnom poglavlju, rezultate za Hrvatsku uspoređujemo s rezultatima ostalih rubnih zemalja.

3.1.1. Metodologija

Šokove agregatne ponude i potražnje identificiramo postavljanjem restrikcija na funkcije impulsnog odziva u bivarijatnom bajesovskom VAR modelu. Dosadašnja istraživanja o usklađenosti šokova agregatne ponude i potražnje redovito slijede metodologiju predloženu u Bayoumi i Eichengreen (1992.). Ukratko, identifikacija se tada temelji na pretpostavci da jedino šokovi ponude mogu utjecati na razinu BDP-a u dugom roku, što je implementirano kao u Blanchard i Quah (1989). No ovakva strategija identifikacije ne osigurava uobičajenu korelaciju između BDP-a i inflacije – zbog šokova potražnje ona bi trebala biti pozitivna, a nakon šokova ponude negativna. Za razliku od standardne metode iz Bayoumi i Eichengreen (1992.), u ovom će se radu navedeni strukturni šokovi stoga identificirati kombinacijom dugoročnih nultih restrikcija te kratkoročnih restrikcija predznaka na funkcije impulsnog odziva kao što je prethodno učinjeno u Comunale i Kunovac (2017.). U tu svrhu korišten je algoritam predložen u Arias *et al.* (2014.) implementiran u *toolboxu* Kotarac i Kunovac (2015.).[8]

3.1.2. Podaci

Varijable o ekonomskoj aktivnosti i cijenama odnose se na minimalan skup varijabla potrebnih za identifikaciju navedenih šokova ponude i potražnje. U radu se stoga koristimo realnim tromjesečnim rastom BDP-a i tromjesečnom stopom inflacije kao endogenim varijablama u opisanom modelu. Obje varijable izračunate su kao tromjesečna promjena prirodnog logaritma. Korištene su vremenske serije BDP-a opisane u prethodnom poglavlju. Cijene su mjerene sezonski prilagođenim harmoniziranim indeksom potrošačkih cijena. Navedene serije potrošačkih cijena preuzete su iz baze podataka Europske središnje banke. Dužina uzorka za sve VAR modele obuhvaća razdoblje od prvog tromjesečja 1998. do drugog tromjesečja 2016. Procijenjeni su pojedinačni bivarijatni VAR modeli za svaku zemlju iz prethodno opisane grupe 24 zemlje članice EU-a.

8 MATLAB-ov kod kao i *toolbox* dostupni su na zahtjev.

3.1.3. Identifikacija

Korištene restrikcije potrebne za identifikaciju šokova agregatne ponude i potražnje dane su u Tablici 1. Stupci se odnose na reakciju endogenih varijabla, a redci na šokove. Pri identifikaciji razlikujemo dvije vrste restrikcija s obzirom na horizont djelovanja pojedinog šoka: kratkoročne i dugoročne. *Kratkoročne restrikcije* postavljene su na impulsne odzive isključivo u trenutku djelovanja odgovarajućeg šoka na endogene varijable. Navedene restrikcije prikazane su u gornjem dijelu Tablice 1. ($t = 0$). Pretpostavljena je uobičajena identifikacija prema kojoj pozitivan šok potražnje u kratkom roku povećava BDP i cijene, dok pozitivan šok ponude povećava BDP te istovremeno smanjuje cijene. Šokovima ponude u pravilu se smatraju šokovi produktivnosti, dok se šokovima potražnje primjerice smatraju razni šokovi preferencija, pouzdanja potrošača ili šokovi ekonomske politike. Za razliku od kratkoročnih, *dugoročne restrikcije* postavljene su na kumulativni utjecaj određenog šoka na odgovarajuću varijablu. U ovom VAR modelu uključena je restrikcija kojom pretpostavljamo da šokovi potražnje u dugom roku ne mogu utjecati na BDP, što znači da su šokovi potražnje tranzitorni. S druge strane, na šokove ponude nisu postavljene restrikcije, čime je omogućen permanentan utjecaj navedenih šokova na ekonomsku aktivnost. Takve dugoročne restrikcije u skladu su s dosadašnjom literaturom o usklađenosti šokova ponude i potražnje koja se temelji na identifikaciji predloženoj u Bayoumi i Eichengreen (1992.), dok kombinacija takvih dugoročnih restrikcija s kratkoročnim restrikcijama predznaka predstavlja doprinos postojećoj literaturi o analizi usklađenosti šokova.

Tablica 1. Restrikcije za identifikaciju šokova

	BDP	inflacija
	kratki rok (t = 0)	
Agregatna potražnja	+	+
Agregatna ponuda	+	–
	dugi rok	
Agregatna potražnja	0	?
Agregatna ponuda	?	?

Napomena: Pozitivna reakcija endogene varijable na strukturni šok označena je s +, negativna s –, dok ? znači da restrikcija nije postavljena na odgovarajuću varijablu.

3.1.4. Rezultati

Slike 5. (a) i (b) prikazuju identificirane šokove agregatne ponude i potražnje za Hrvatsku te prosjek navedenih šokova za zemlje jezgre europodručja, procijenjene prethodno opisanim VAR modelima.[9] Slika 5. (b) sugerira kako su šokovi potražnje u Hrvatskoj uvelike korelirani sa šokovima potražnje u zemljama jezgre europodručja. Snažna sinkroniziranost posebno je izražena neposredno prije i tijekom zajedničke krize 2008. i početkom 2009. godine, dok je divergentno kretanje šokova zabilježeno isključivo u razdoblju od 1998. do 2001. godine. S druge strane, šokovi ponude prikazani na Slici 5. (a) pokazuju nešto manju korelaciju tijekom cjelokupnog razdoblja. Niža korelacija šokova agregatne ponude nije iznenađujuća jer je hrvatska ekonomija tijekom procesa tranzicije prolazila kroz razdoblje značajnih strukturnih promjena. Takve bi promjene ponajprije trebale biti vidljive u šokovima ponude odnosno šokovima produktivnosti koji su povezani s dugoročnim promjenama u strukturi ekonomije.

Kako bismo navedene rezultate o usklađenosti šokova ponude i potražnje usporedili s ostalim rubnim zemljama, na Slici 6. dan je prikaz prosječnih koeficijenata korelacije šokova svake zemlje sa šokovima zemalja jezgre europodručja. Slika 6. (a) odnosi se na cijeli uzorak, Slika 6. (b) na prvu polovicu, a Slika 6. (c) na drugu polovicu uzorka. Na svim slikama na apscisi prikazana je korelacija šokova ponude, a na ordinati korelacija šokova potražnje. Prikazani rezultati potvrđuju preliminarne nalaze o tome kako su hrvatski šokovi potražnje prilično dobro sinkronizirani sa šokovima potražnje jezgre europodručja. Naime, Hrvatska pripada skupini zemalja s najvećim koeficijentom korelacije za šokove potražnje. Međutim, rezultati vezani uz šokove ponude sugeriraju kako je hrvatsko gospodarstvo nešto manje usklađeno s gospodarstvom europodručja. Naime,

9 Za sve zemlje pretpostavljena su dva pomaka (engl. *lag*) endogenih varijabla.

Slika 5. Strukturni šokovi identificirani bivarijatnim BVAR modelom

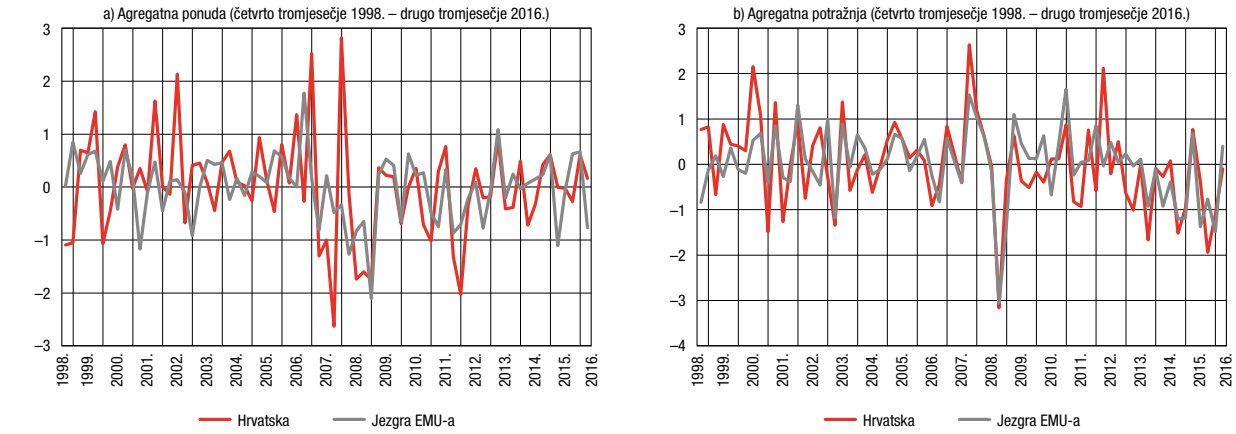

Napomena: Šokovi za jezgru europodručja izračunati su kao prosjek pojedinačnih šokova sedam zemalja jezgre europodručja.
Izvor: HNB

koeficijent korelacije šokova ponude između Hrvatske i zemalja jezgre europodručja nalazi se ispod prosjeka analiziranog uzorka. Zatim, slično kao i u prethodnom poglavlju, rezultati upućuju na konvergenciju ekonomskih šokova Hrvatske i zemalja jezgre europodručja. Naime, u drugoj polovici uzorka (Slika 6. (c)) Hrvatska je smještena u gornjem desnom uglu (*sjeveroistočno*), što znači da su hrvatski šokovi ponude i potražnje nešto

Slika 6. Korelacije šokova ponude i potražnje sa zemljama jezgre europodručja

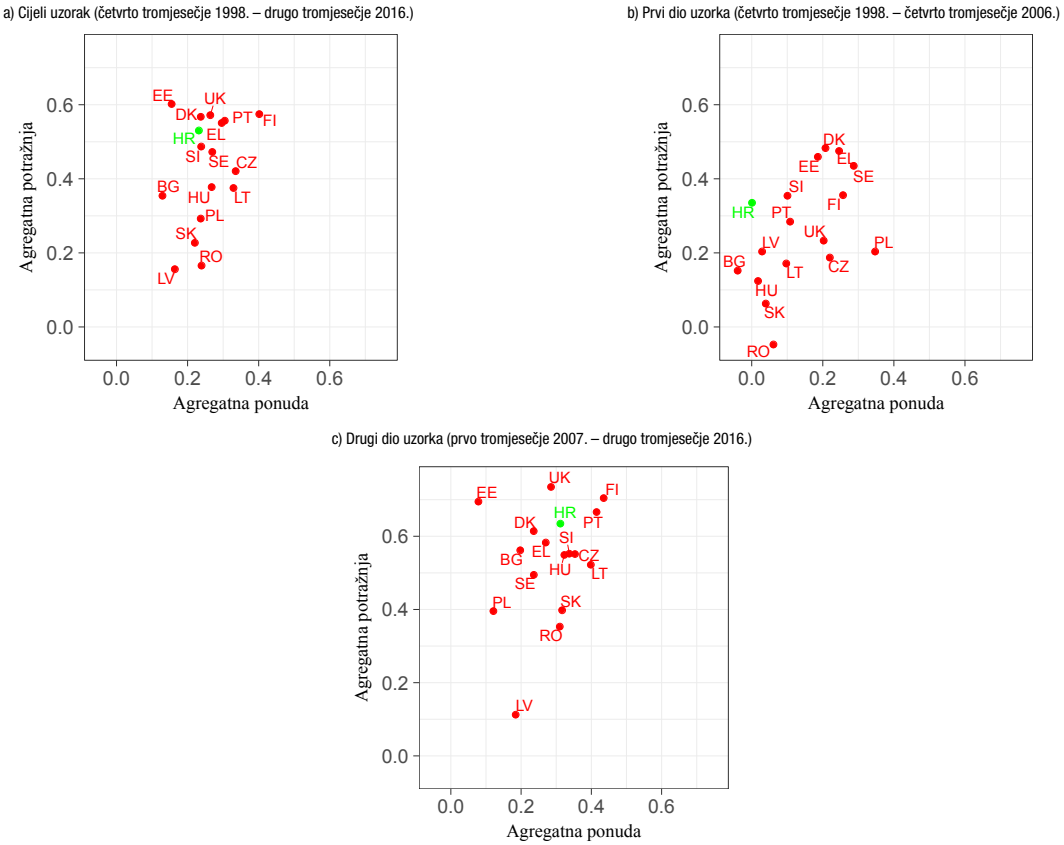

Napomena: Korelacije sa zemljama jezgre izračunate su kao ponderiran prosjek korelacije odgovarajuće rubne zemlje sa sedam zemalja jezgre, gdje se ponderi odnose na udio svake od navedenih sedam zemalja u BDP-u europodručja.
Izvor: HNB

jače korelirani sa šokovima ponude i potražnje u zemljama jezgre europodručja.

Slično kao u prethodnom poglavlju, provedeno je višedimenzionalno skaliranje na temelju korelacije šokova ponude i potražnje za sve parove zemalja uključene u ovu analizu za cjelokupni uzorak odnosno za dva poduzorka. Blizina država na mapi upućuje na visoku korelaciju šokova. Sve navedene bilateralne korelacije šokova ponude i potražnje dane su u tablicama 6. i 7. u Dodatku rada. Slike 7. (b), (d) i (f) sugeriraju da su hrvatski šokovi potražnje vrlo slični šokovima većine članica europodručja te da navedena relativna usklađenost šokova raste kroz vrijeme. S druge strane, slike 7. (a), (c) i (e) općenito pokazuju nešto veću raspršenost zemalja na temelju korelacija šokova ponude te nešto veće razlike između dva analizirana poduzorka. Hrvatska je prema tim rezultatima u razdoblju 2007. – 2016. u blizini nekih zemalja jezgre europodručja kao što su Španjolska, Austrija ili Francuska, dok su neke zemlje, kojima je prema rezultatima u drugom poglavlju ciklus znatno usklađen s hrvatskim, nešto udaljenije. To se prije svega odnosi na Nizozemsku i Njemačku te neke rubne zemlje, kao što su Bugarska, Madžarska i Slovačka. Stoga je važno upozoriti kako se sličnost dviju ekonomija s aspekta šokova ne mora nužno preslikati u sličnost ciklusa tih zemalja. Takve razlike u relativnom

Slika 7. Rezultat višedimenzionalnog skaliranja na temelju korelacije šokova ponude i potražnje

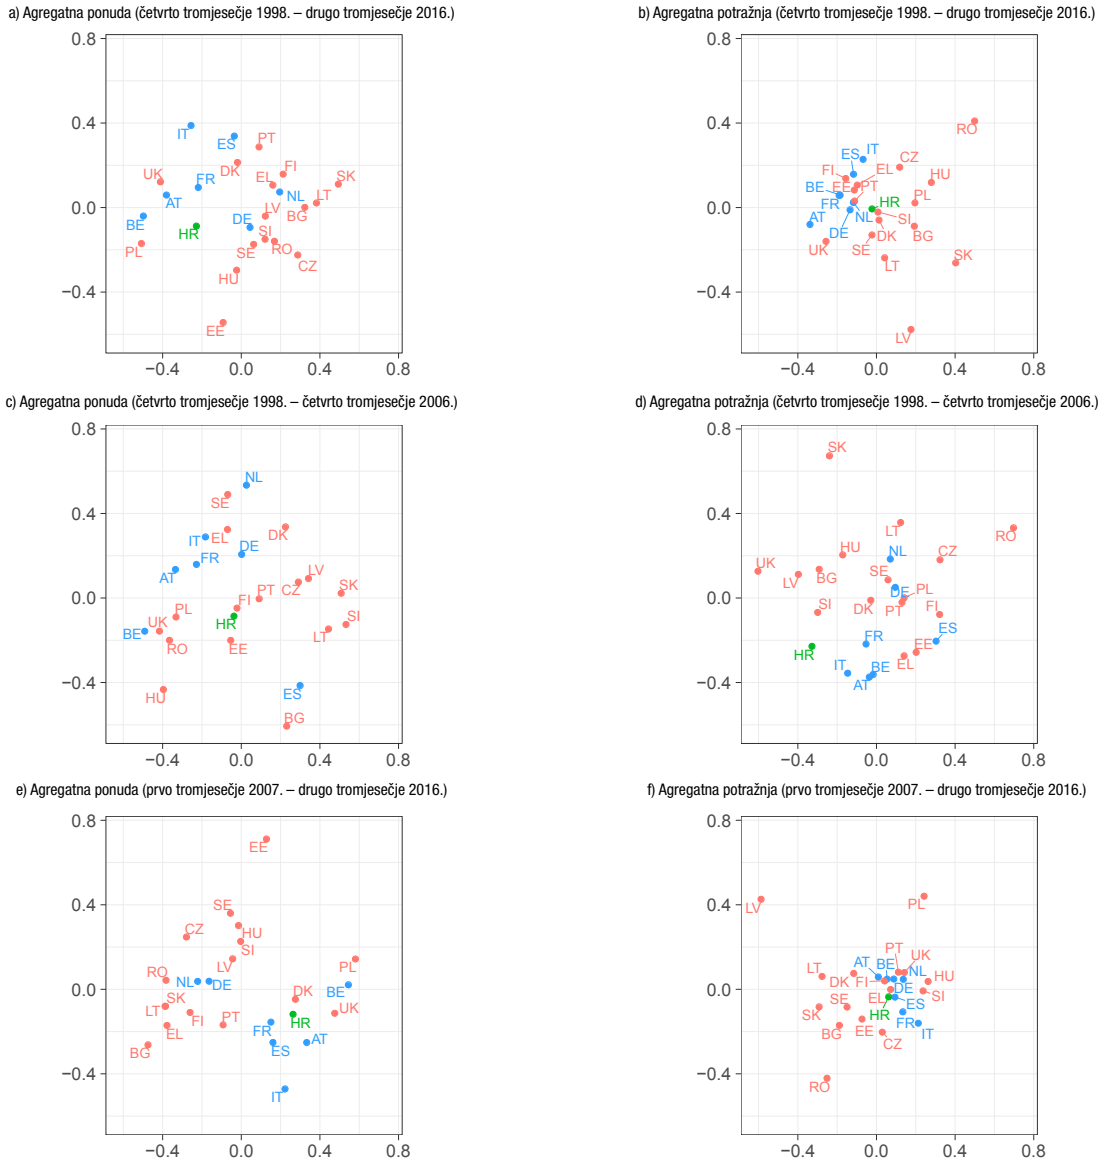

Izvor: HNB

rangiranju pojedinih zemalja između ovog i prethodnog poglavlja upućuju na dodatan oprez pri donošenju zaključaka o očekivanim troškovima zajedničke monetarne politike te naglašavaju važnost analiziranja navedenog pitanja korištenjem različitih metodoloških alata i konceptualnih pristupa.

3.2. Važnost simetričnih i asimetričnih šokova za domaći BDP

Dosad smo pratili literaturu i usklađenost šokova mjerili korelacijama. No, treba imati na umu očiti nedostatak ovakve analize strukturnih šokova – zanemarivanje endogenih propagacijskih mehanizama odnosno reakcija ekonomskih varijabla na strukturne šokove. Važno je naglasiti kako je zajednički ciklus, tj. onaj na koji reagira zajednička monetarna politika, na kraju određen *kombinacijom šokova i transmisijskih mehanizama* pojedine ekonomije. Srodna se literatura (primjerice Bayoumi i Eichengreen, 1992.), nažalost, redovito fokusira na usklađenost šokova i pritom zanemaruje propagaciju tih šokova i naposljetku tako ignorira ključan problem – ukupan utjecaj šokova na makroekonomske varijable. Analiza koreliranosti šokova stoga nije dostatna za donošenje čvrstih zaključaka o adekvatnosti zajedničke monetarne politike ako se transmisijski mehanizmi u promatranim ekonomijama značajno razlikuju. S tim u vezi Peersman (2011.) predlaže podjelu na *simetrične* i *asimetrične* šokove prema njihovu utjecaju na varijable male domaće ekonomije (Ujedinjena Kraljevina) i velike strane ekonomije (europodručje). Na taj način izravno odgovara na pitanje o važnosti simetričnih odnosno asimetričnih šokova za malu otvorenu ekonomiju i time analizira zadovoljavanje jednog od OCA kriterija. U tu svrhu procjenjuje bogatiji VAR model u kojem je simultano modelirana domaća i strana ekonomija (engl. *two country model*), što omogućuje detaljniju analizu prirode šokova koji generiraju ciklus domaće ekonomije. Peersman (2011.) definira simetrične šokove kao one šokove koji djeluju na domaće i strane varijable uz *isti predznak*, dok su asimetrični šokovi oni koji djeluju na domaće varijable uz *suprotan predznak* u odnosu na strane varijable. Smatramo da navedena identifikacija nije u potpunosti relevantna za skup zemalja koji analiziramo i pretpostavka o suprotnim reakcijama ekonomskih varijabla na istu vrstu šoka kod zemalja EU-a čini se prejakom budući da one dijele zajedničke institucije i sudjeluju na zajedničkom tržištu. Primjerice, Peersman pretpostavlja da asimetričan šok agregatne ponude (produktivnost/tehnologija) smanjuje domaći BDP i povećava domaće cijene, dok istovremeno on povećava strani BDP i smanjuje strane cijene. Navedeno implicira da nije samo izostalo prelijevanje tehnologije, već bi porast tehnologije u jednoj zemlji doveo do smanjenja tehnologije u drugoj zemlji. U radu nadograđujemo identifikaciju opisanu u Peersman (2011.) i dodajemo u model *domaće, idiosinkratske* šokove. Rezultati pokazuju da su takvi šokovi glavni izvor asimetričnosti za malu ekonomiju kao što je Hrvatska.[10]

3.2.1. Metodologija i identifikacija šokova

Slično kao u prethodnom potpoglavlju, šokovi su identificirani kombiniranjem restrikcija predznaka u kratkom roku i nultih restrikcija u dugom roku, primjenom bajesovskog VAR modela za simultano modeliranje dviju država (engl. *two country VAR model*). Osnovna je razlika u odnosu na prethodno procijenjeni VAR model u tome što su, osim domaćih, uključene i varijable europodručja. Navedeno proširenje VAR modela uključivanjem stranih varijabla omogućuje zasebnu identifikaciju simetričnih od asimetričnih šokova. Stoga ovdje korišteni VAR model uključuje sljedećih šest varijabla: domaći rast BDP-a i domaću inflaciju, stopu promjene realnog tečaja, inflaciju i rast BDP-a europodručja te kratkoročnu referentnu kamatnu stopu europodručja. Kao i u prethodnom poglavlju, pretpostavili smo dva pomaka endogenih varijabla. Većina rubnih zemalja odnosi se na vrlo male ekonomije čiji BDP uglavnom ne prelazi 1% BDP-a europodručja te stoga u VAR modele uključujemo blok egzogene restrikcije. Na taj način uvodimo pretpostavku da mala domaća ekonomija ne može utjecati na veliku ekonomiju odnosno na europodručje. Detaljan opis implementacije navedenih blok egzogenih

10 Ovo smo potvrdili empirijski usporedbom identifikacije koja uključuje domaće šokove s identifikacijom iz Peersman (2011.) primjenom identičnog uzorka i jednakoga reduciranog oblika VAR modela za Hrvatsku. U tu smo svrhu usporedili udio prihvaćenih iteracija u korištenom algoritmu za dvije alternativne identifikacije. Pojednostavnjeno, u slučaju da je taj udio visok – model sugerira kako su postavljene restrikcije smislene. Prema rezultatima provedene analize navedeni je udio prihvaćenih iteracija za otprilike 40 puta veći za ovdje predloženu identifikaciju u usporedbi s identifikacijom iz Peersman (2011.).

restrikcija u sličnom VAR modelu dan je u Jovičić i Kunovac (2017.).

Tablica 2. prikazuje restrikcije kojima su identificirani strukturni šokovi u korištenom VAR modelu. Slično kao u Tablici 1., gornji dio prikazuje kratkoročne restrikcije za svaki analizirani šok, dok donji dio prikazuje dugoročne restrikcije. Kao što je ranije naglašeno, kratkoročne restrikcije postavljene su na impulsne odzive isključivo u trenutku djelovanja odgovarajućeg šoka na endogene varijable, dok su dugoročne restrikcije postavljene na dugoročni utjecaj određenog šoka na odgovarajuću varijablu. Za razliku od uobičajene podjele na domaće i strane šokove, ovdje je predložena podjela na simetrične i asimetrične šokove, što znači da je naglasak na onim stranim šokovima koji dovode do simetrične reakcije BDP-a u domaćoj i stranoj ekonomiji.

Pozitivni simetrični šokovi agregatne potražnje inicijalno povećavaju BDP i cijene u obje ekonomije te podižu kamatnu stopu europodručja zbog reakcijske funkcije monetarne politike. Restrikcija nije postavljena na reakciju realnog tečaja, što odražava ideju da nije *a priori* jasno hoće li navedeni šok u jačoj mjeri utjecati na domaće cijene ili na cijene europodručja. Također pretpostavljamo kako u dugom roku, slično kao i u ranije opisanom manjem VAR modelu, šokovi potražnje ne mogu utjecati na BDP. Stoga je nulta restrikcija u dugom roku postavljena na reakcije BDP-a obiju zemalja. Ekspanzivni simetrični šokovi agregatne ponude djeluju na isti način na BDP i cijene obiju zemalja: povećava se BDP i smanjuju cijene u kratkom roku, dok dugoročne restrikcije nisu postavljene. Također je uvedena restrikcija na kamatnu stopu europodručja, za koju pretpostavljamo da se u trenutku pozitivnoga simetričnog šoka smanjuje zbog reakcijske funkcije monetarne politike zbog pada cijena i snažnijeg porasta potencijalnog BDP-a u odnosu na porast ostvarenog BDP-a (pad cikličke komponente BDP-a).

Tablica 2. Restrikcije za identifikaciju simetričnih i asimetričnih šokova

	BDP	Inflacija	Tečaj	EA BDP	EA inflacija	K. s. EA
			kratki rok (t = 0)			
Simetrični šokovi						
Agregatna potražnja	+	+	?	+	+	+
Agregatna ponuda	+	–	?	+	–	–
Asimetrični šokovi						
Idiosinkratska agregatna potražnja	+	+	?	0	0	0
Idiosinkratska agregatna ponuda	+	–	?	0	0	0
Asimetrična realna aktivnost	+	?	?	–	?	?
Ostali šokovi						
Monetarna politika ESB-a	?	?	?	+	+	–
			dugi rok			
Simetrični šokovi						
Agregatna potražnja	0	?	?	0	?	?
Agregatna ponuda	?	?	?	?	?	?
Asimetrični šokovi						
Idiosinkratska agregatna potražnja	0	?	?	?	?	?
Idiosinkratska agregatna ponuda	?	?	?	?	?	?
Asimetrična realna aktivnost	?	?	?	?	?	?
Ostali šokovi						
Monetarna politika ESB-a	?	?	?	0	?	?

Osim navedena dva simetrična šoka, identificirali smo tri asimetrična šoka te šok monetarne politike ESB-a. Asimetrični su šokovi: idiosinkratski šok domaće potražnje, idiosinkratski šok domaće ponude te asimetrični šok realne aktivnosti. Pozitivan asimetričan (idiosinkratski) šok agregatne potražnje dovodi do porasta domaćeg BDP-a i cijena u kratkom roku, dok strane varijable ostaju nepromijenjene. Dodatno, zbog restrikcija blok egzogenosti, endogeni transmisijski mehanizmi ne mogu dovesti do promjena u varijablama europodručja. Ponovno je pretpostavljeno kako je navedeni šok prolaznoga karaktera, odnosno kako reakcija domaćeg BDP-a u dugom roku konvergira u nulu. Pozitivan asimetričan (idiosinkratski) šok agregatne ponude

povećava domaći BDP i smanjuje domaće cijene, dok strane varijable ne reagiraju na navedeni šok. Asimetrični šok realne aktivnosti definiran je kao šok koji dovodi do suprotnih reakcija domaćeg BDP-a u odnosu na reakciju BDP-a europodručja. Za razliku od Peersman (2011.), u ovom radu ne postavljamo restrikcije na ostale varijable. Stoga navedeni šok objedinjuje asimetrične šokove agregatne potražnje, ponude i monetarne politike. Takva je identifikacija nužna s obzirom na maksimalan broj šokova koje možemo identificirati i, istovremeno, ona reflektira ranije opisane nedostatke identifikacije asimetričnih šokova predložene u Peersman (2011.). Posljednji šok identificiran u ovom modelu jest šok monetarne politike ESB-a. Ovdje se radi o restrikcijama koje su uobičajene za monetarne VAR modele prema kojima se pretpostavlja kako egzogeno smanjenje referentne kamatne stope ekspanzivno djeluje na BDP europodručja te povećava cijene, dok restrikcije na domaće varijable nisu postavljene. U skladu sa standardnom monetarnom teorijom navedeni šok nema dugoročnih efekata na BDP.

Kako bismo usporedili važnost tako definiranih asimetričnih u odnosu na simetrične šokove, za svaku zemlju računamo udio simetričnih i asimetričnih šokova u povijesnoj dekompoziciji BDP-a procijenjenog VAR modela.

3.2.2. Podaci

Za domaći blok korištene su vremenske serije BDP-a i inflacije za 17 rubnih zemalja koje su prethodno opisane. Korištena mjera realnog tečaja jest realni efektivni tečaj domaće ekonomije prema zemljama europodručja preuzet s Eurostata. Kao što je već naglašeno, strani blok uključuje BDP europodručja, HIPC inflaciju europodručja te referentnu kratkoročnu kamatnu stopu europodručja. Korištena kamatna stopa europodručja je *Shadow rate* (Wu, Xia, 2016.), odnosno kamatna stopa korigirana za nestandardne mjere monetarne politike ESB-a. Za VAR modele u kojima domaću ekonomiju predstavlja neka od rubnih zemalja članica europodručja BDP i inflacija u stranom bloku prilagođeni su za BDP i inflaciju odgovarajuće domaće ekonomije. Preciznije, za takve VAR modele strani BDP odnosi se na sumu BDP-a svih zemalja europodručja osim BDP-a analizirane zemlje. Na sličan način, na temelju pondera s Eurostata, izračunat je i HIPC europodručja za modele u kojima neka od rubnih zemalja europodručja predstavlja domaću ekonomiju. Sve varijable, osim kamatne stope, uključene su u model u log-diferencijama.

3.2.3. Rezultati

Slika 8. prikazuje povijesnu dekompoziciju godišnje stope rasta hrvatskog BDP-a na identificirane strukturne šokove[11]. Iz slike je vidljivo da su prije globalne financijske krize, osim simetričnih šokova potražnje,

Slika 8. Povijesna dekompozicija hrvatskog BDP-a

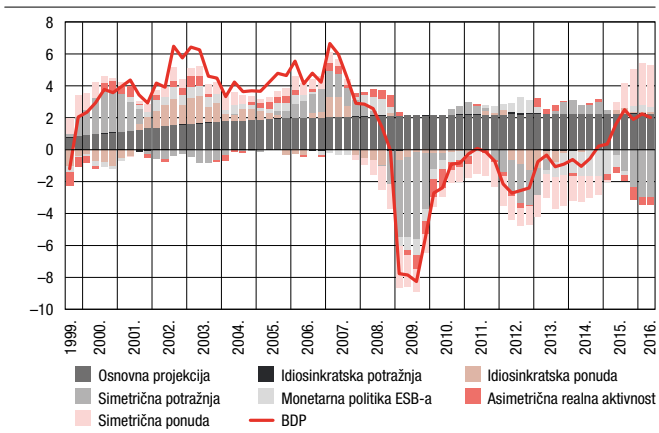

Napomena: Prikazani su doprinosi pojedinih šokova godišnjoj stopi rasta BDP-a procijenjeni BVAR modelom male otvorene ekonomije.
Izvor: HNB

11 Na Slici 23. u Dodatku rada prikazane su funkcije impulsnog odziva za varijable uključene u VAR model za Hrvatsku.

asimetrični šokovi ponude najviše pridonosili BDP-u. Navedeni su rezultati u skladu s rezultatima o nešto nižoj koreliranosti šokova agregatne ponude u razdoblju prije 2006. godine, što je prikazano u prethodnom potpoglavlju. Kao što je rečeno, takvi nalazi nisu iznenađujući s obzirom na proces tranzicije kroz koji je prolazila hrvatska ekonomija u kojima su dominantnu ulogu imali razni domaći šokovi koji utječu na produktivnost u dugom roku. Međutim, u razdoblju od 2007. do 2016. domaći je BDP pod dominantnim utjecajem simetričnih šokova, što također potvrđuje većinu prethodno prikazanih rezultata.

Na Slici 9. prikazana je relativna važnost simetričnih šokova za objašnjavanje dinamike domaćeg BDP-a. Preciznije, u svakom vremenskom trenutku zbrojene su apsolutne vrijednosti doprinosa simetričnih šokova koje su zatim podijeljene sa sumom apsolutnih vrijednosti doprinosa svih strukturnih šokova. Slično kao i kod slika prikazanih u prethodnom poglavlju, crvenom linijom označeni su doprinosi simetričnih šokova za Hrvatsku, a plavom prosjek doprinosa simetričnih šokova za sve ostale rubne zemlje EU-a zajedno s intervalom od jedne standardne devijacije. Potrebno je naglasiti kako su doprinosi šoka monetarne politike ESB-a pridruženi simetričnim šokovima jer bi ulaskom u zajedničku monetarnu uniju navedeni šok postao simetričan.

Slika 9. Doprinosi simetričnih šokova BDP-u

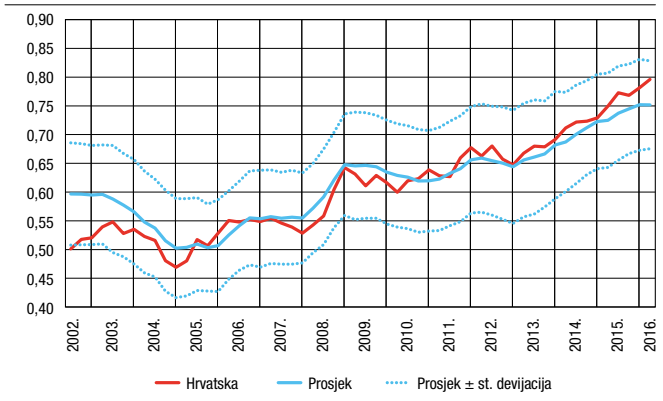

Napomena: Doprinosi simetričnih šokova izračunati su kao postotni udio simetričnih šokova (i šokova monetarne politike) u povijesnoj dekompoziciji tromjesečne stope rasta domaćeg BDP-a. Prikazani su četverogodišnji pomični prosjeci.
Izvor: HNB

Slika 9. upućuje na snažan porast doprinosa simetričnih šokova za hrvatski BDP, što potvrđuje preliminarne nalaze iz Slike 8. Na Slici 9. također se vidi kako je navedeni porast doprinosa simetričnih šokova u skladu s prosječnim rezultatom ostalih zemalja.[12] To navodi na zaključak da troškovi povezani s gubitkom autonomnog vođenja monetarne politike za Hrvatsku ne bi trebali biti značajni.

Potrebno je naglasiti kako dio asimetričnih šokova također može dovesti do simetrične reakcije u ekonomskim varijablama. Drugim riječima, šok koji je identificiran kao asimetričan, odnosno idiosinkratski šok može u određenim trenucima djelovati na domaći BDP u istom smjeru kao simetrični šok. Ovdje nudimo dva potencijalna objašnjenja za takvu simetričnu reakciju. Prvo potencijalno objašnjenje jest da ona može u potpunosti biti slučajna – gospodarska kretanja mogu biti usklađena zbog potpuno nevezanih razloga. Alternativno objašnjenje je da u određenim trenucima domaći šokovi, iako egzogeni po definiciji, mogu biti motivirani ekonomskim kretanjima ili akcijama/najavama ekonomskih politika europodručja. Potrebno je naglasiti kako se egzogenost odnosi na informacijski skup uključen u VAR model, dok je informacijski skup agenata u ekonomiji znatno širi. Stoga je moguće da su u određenim trenucima domaći asimetrični šokovi, koji po definiciji ne utječu na varijable europodručja, uzrokovani nekim informacijama iz europodručja koje nisu uključene u VAR model. Primjer su takvih šokova domaće fiskalne konsolidacije motivirane sličnim konsolidacijama u europodručju. Zatim, pokretanje investicijskih projekata u sektoru turizma kao reakcija na promjenu u ekonomskoj

12 U Dodatku rada pojedinačno su prikazani doprinosi simetričnih šokova za sve analizirane rubne zemlje. Slika 18. daje usporedbu rezultata za Hrvatsku i rubne zemlje europodručja, odnosno Slika 19. za Hrvatsku i ostale rubne zemlje EU-a koje nisu članice europodručja.

aktivnosti u europodručju – posebice ako je takva reakcija snažnija od predvidive endogene reakcije domaćeg BDP-a na strane šokove. Konačno, domaći šokovi pouzdanja potrošača koji su motivirani ekonomskim kretanjima u europodručju također mogu poslužiti kao primjer takvih šokova. Neovisno o stvarnom izvoru takvog šoka, na Slici 10. pribrajamo doprinose takvih asimetričnih šokova ranije prikazanim doprinosima simetričnih šokova. Prema prikazanim rezultatima takvi asimetrični šokovi koji dovode do simetrične reakcije u domaćem BDP-u, ovisno o promatranom razdoblju, objašnjavaju između 10% i 30% dinamike hrvatskog BDP-a. Iz slike je vidljivo da je tijekom gotovo cjelokupnog razdoblja zajednički doprinos navedenih i simetričnih šokova iznosio više od 70% dinamike hrvatskog BDP-a. Slika 10. također sugerira kako pri kraju uzorka navedeni doprinosi premašuju 85% te su značajno veći u usporedbi s prosjekom ostalih rubnih zemalja.[13] Iz navedenih rezultata možemo zaključiti kako su simetrični šokovi, zajedno s asimetričnim šokovima koji dovode do simetrične reakcije u domaćem BDP-u, zaista dominantni za objašnjavanje dinamike hrvatskog BDP-a.

Slika 10. Doprinosi šokova koji dovode do simetrične reakcije u BDP-u

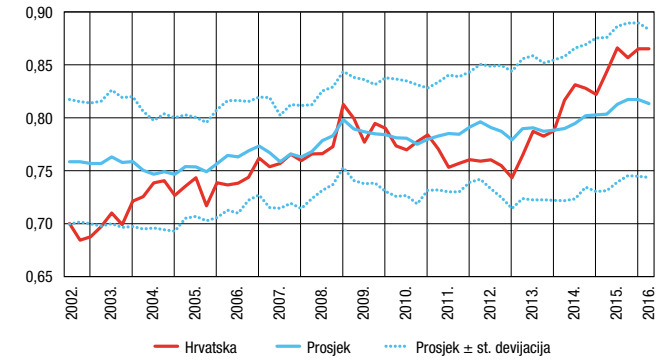

Napomena: Doprinosi simetričnih šokova izračunati su kao postotni udio simetričnih šokova (te šokova monetarne politike) u povijesnoj dekompoziciji tromjesečne stope rasta domaćeg BDP-a. Doprinosima simetričnih šokova pribrojeni su doprinosi asimetričnih šokova ako im je u danom trenutku jednak predznak. Prikazani su četverogodišnji pomični prosjeci.
Izvor: HNB

4. Zaključak

U radu smo analizirali usklađenost poslovnih ciklusa te ekonomskih šokova između Hrvatske i zemalja jezgre europodručja. Dodatno smo istražili u kojoj je mjeri hrvatski BDP pod utjecajem simetričnih (zajedničkih) i asimetričnih šokova. Dobivene rezultate usporedili smo s odgovarajućim rezultatima za ostale rubne zemlje EU-a. Rezultati prikazani u radu trebali bi pridonijeti javnoj raspravi o očekivanim troškovima povezanima s prihvaćanjem zajedničke monetarne politike nakon što RH pristupi europodručju. Poznato je, naime, kako se uz ulazak u monetarnu uniju vezuju potencijalne koristi i troškovi novih zemalja članica, pri čemu se troškovi ponajprije očituju u gubitku autonomije u vođenju vlastite protucikličke monetarne politike. Osnovna OCA teorija navodi kako će zajednička monetarna politika odgovarati svim članicama monetarne unije ako su ciklusi i ekonomski šokovi tih zemalja međusobno usklađeni.

Provedena analiza upućuje na sljedećih nekoliko zaključaka. Prvo, usklađenost poslovnih ciklusa te korelacija ekonomskih šokova između Hrvatske i zemalja jezgre europodručja relativno je visoka. Prikazane mjere

13 U Dodatku rada pojedinačno su prikazani doprinosi navedene šire definicije simetričnih šokova za sve analizirane rubne zemlje. Na Slici 20. dana je usporedba rezultata za Hrvatsku i rubne zemlje europodručja, odnosno na Slici 21. za Hrvatsku i ostale rubne zemlje EU-a koje nisu članice europodručja.

sličnosti i fazne sinkroniziranosti hrvatskog ciklusa s ciklusom zemalja jezgre europodručja veće su u usporedbi s navedenim mjerama za druge rubne zemlje EU-a. Sličan zaključak vrijedi za korelaciju šokova potražnje, dok je korelacija šokova ponude između Hrvatske i zemalja jezgre europodručja nešto manja. Drugo, simetrični (zajednički) šokovi dominantni su za objašnjavanje dinamike domaćeg BDP-a, dok su doprinosi asimetričnih šokova znatno manji. Treće, rezultati upućuju na konvergenciju šokova ponude i potražnje te poslovnih ciklusa između Hrvatske i zemalja jezgre europodručja. Preciznije, u razdoblju nakon 2006. godine usklađenost ciklusa između Hrvatske i europodručja značajno je viša u odnosu na razdoblje prije 2006. godine. Također, iz rezultata je vidljivo da u posljednjih nekoliko godina raste važnost simetričnih šokova za hrvatski BDP te u recentnom razdoblju navedeni simetrični šokovi, ovisno o korištenoj mjeri, objašnjavaju između 75% i 85% dinamike hrvatskog BDP-a.

Iz svega navedenog možemo zaključiti kako uvođenje eura i s time povezano prihvaćanje zajedničke monetarne politike ne bi trebali biti značajan trošak za hrvatsku ekonomiju s aspekta mogućnosti protucikličkog djelovanja monetarne politike.

Literatura

[1] Arčabić, V. (2011.): *Usklađenost poslovnih ciklusa Republike Hrvatske sa zemljama Europske unije*, Zbornik Ekonomskog fakulteta u Zagrebu, 9(1), 127 – 144

[2] Arias, J. E., Rubio-Ramirez, J. F., Waggoner, D. F. (2014.): *Inference Based on SVARs Identified with Sign and Zero Restrictions: Theory and Applications*, International Finance Discussion Papers 1100, Board of Governors of the Federal Reserve System (U.S.)

[3] Bayoumi, T., Eichengreen, B. (1992.): *Shocking aspects of European monetary unification*, NBER Working Paper, No. 3949

[4] Bayoumi, T., Eichengreen, B. (1993.): *Is there a conflict between EC enlargement and European monetary unification*, Greek Economic Review 15, No. 1, pp 131 – 154

[5] Bayoumi, T., Eichengreen, B. (1994.): *One money or many? Analysing the prospects for monetary unification in various parts of the World*, Princeton Studies in International Finance No. 76, rujan

[6] Belullo, A., Šonje, V., Vrbanc, I. (2000.): *Je li Srednja Europa optimalno valutno područje?*, HNB, Istraživanja, I-8

[7] Belke, A., Domnick, C., Gros, D. (2017.): *Business Cycle Desynchronisation: Amplitude and Beta vs. Comovement*, Intereconomics, 52(4), 238 – 241

[8] Blanchard, O. J., Quah, D. (1989.): *The dynamic effects of aggregate demand and supply disturbances*, American Economic Review, 79(4), 655 – 673

[9] Broz, T. (2010.): *Introduction of the euro in CEE countries – is it economically justifiable? The Croatian case*, Post-Communist Economies, Vol. 22, No. 4

[10] Cerqueira, P. A., Martins, R. (2009.): *Measuring the determinants of business cycle synchronization using a panel approach*, Economics Letters, 102(2), 106 – 108

[11] Cerqueira, P. A. (2013.): *A closer look at the world business cycle synchronization*, International Economics and Economic Policy, 10(3), 349 – 363

[12] Comunale, M., Kunovac, D. (2017.): *Exchange rate pass-through in the Euro Area*, ECB Working Paper, No. 2003

[13] Dumičić, K., Palić, I., Sprajaček, P. (2015.): *The role of external shocks in Croatia: Block exogeneity SVAR approach*, Journal of Economic and Social Development, 2(1), 44 – 54

[14] Frenkel, M., Nickel, C. (2005.): *How symmetric are the shocks and the shock adjustment dynamics between the Euro Area and Central and Eastern European Countries?*, JCMS: Journal of Common Market Studies, 43(1), 53 – 74

[15] Frankel, J. A., Rose, A. K. (1998.): *The endogenity of the optimum currency area criteria*, The Economic Journal, 108(449), 1009 – 1025

[16] Fidrmuc, J., Korhonen, I. (2003.): *Similarity of supply and demand shocks between the euro area and the CEECs*, Economic Systems, 27(3), 313 – 334

[17] Hildebrandt, A., Moder, I. (2015.): *Business cycle synchronization between the Western Balkans and the European Union*, Focus on European Economic Integration 3, 8 – 25

[18] Jankov, L., Krznar, I., Kunovac, D., Lang, M. (2008.): *The impact of the USD/EUR exchange rate on inflation in the Central and East European countries*; Comparative Economic Studies, 50(4), 646 – 662

[19] Jovančević, R., Arčabić, V., Globan, T. (2012.): *Prijenos poslovnih ciklusa zemalja Europske unije na Republiku Hrvatsku*, Ekonomski pregled, 63(1 – 2), 3 – 21

[20] Jovičić, G., Kunovac, D. (2017.): *What is Driving Inflation and GDP in a Small European Economy: The Case of Croatia*, CNB Working Papers, W-49

[21] Kenen, P. (1969.): *The theory of optimum currency areas: An eclectic view*, u: Mundell, R. Swoboda, A. (ur.): *Monetary problems of the international economy*, Chicago: University of Chicago Press

[22] Krznar, I., Kunovac, D. (2010.): *Impact of external shocks on domestic inflation and GDP*, CNB Working Papers, W-26

[23] Kunovac, D., Kotarac, K. (2015.): *BVARs with block exogeneity and sign and zero restrictions*, MATLAB Toolbox, Direkcija za modeliranje, HNB

[24] McKinnon, R. I. (1963.): *Optimum currency areas*, The American Economic Review, 53(4), 717 – 725

[25] Mink, M., Jacobs, J. P., de Haan, J. (2012.): *Measuring coherence of output gaps with an application to the euro area*, Oxford Economic Papers, 64(2), 217 – 236

[26] Mundell, R. A. (1961.): *A theory of optimum currency areas*, The American economic review, 51(4), 657 – 665

[27] Obradović, S., Mihajlović, V. (2013.): *Synchronization of business cycles in the selected European countries*, Panoeconomicus, 60(6), 759 – 773

[28] Peersman, G. (2011.): *The relative importance of symmetric and asymmetric shocks: the case of United Kingdom and euro area*, Oxford Bulletin of Economics and Statistics, 73(1), 104 – 118

[29] Šonje, V., Vrbanc, I. (2000.): *Measuring the Similarities of Economic Developments in Central Europe: A Correlation between the Business Cycles of Germany, Hungary, the Czech Republic and Croatia*, CNB Working Papers, W-3

[30] Torgerson, W. S. (1952.): *Multidimensional scaling: I. Theory and method*, Psychometrika, 17(4), 401 – 419

[31] Velickovski, I. (2013.): *Assessing independent monetary policy in small, open and euroized countries: evidence from Western Balkan*, Empirical Economics, 1-20

[32] Wickelmaier, F. (2003.): *An introduction to MDS*, Sound Quality Research Unit, Aalborg University, Danska

[33] Wu, J. C., Xia, F. D. (2016.): *Measuring the Macroeconomic Impact of Monetary Policy at the Zero Lower Bound*, Journal of Money, Credit and Banking, 48(2 – 3), 253 – 291

A Dodatak

A1. Alternativna mjera pomične korelacije ciklusa

Za test robusnosti nalaza dobivenih iz pomičnih korelacija korišten je korelacijski indeks, predložen u radu Cerqueira i Martins (2009.), koji se za dvije serije x_i i x_j definira na sljedeći način:

$$\rho_{ij}(t) = 1 - \frac{1}{2}\left(\frac{x_i(t) - \bar{x}_i}{\sqrt{\frac{1}{T}\sum_{t=1}^{T}(x_i(t) - \bar{x}_i)^2}} - \frac{x_j(t) - \bar{x}_j}{\sqrt{\frac{1}{T}\sum_{t=1}^{T}(x_j(t) - \bar{x}_j)^2}}\right)^2.$$

Nekoliko je prednosti ovakvog indeksa pred pomičnim korelacijama. Glavna prednost je ta da je prosječna vrijednost ovako definiranog indeksa na cijelom uzorku jednaka koeficijentu korelacije između serija x_i i x_j. Nadalje, nema gubitka opažanja te nema potrebe za određivanjem veličine pomičnog prozora. Vrijednosti ovoga indeksa nesimetrične su, u rasponu od $3-2T$ do 1, te smo konstruirali transformirani indeks, prema radu Cerqueira (2013.):

$$\bar{\rho}_{ij}(t) = \tanh\left(\frac{1}{2}\ln\left(\frac{1 + \frac{\rho_{ij}(t)}{2T-3}}{1 - \rho_{ij}(t)}\right)\right),$$

čije su vrijednosti u rasponu od –1 do 1.

A2. Slike i tablice

Slika 11. Korelacije ciklusa rubnih zemalja europodručja (i Hrvatske) s ciklusima zemalja jezgre europodručja

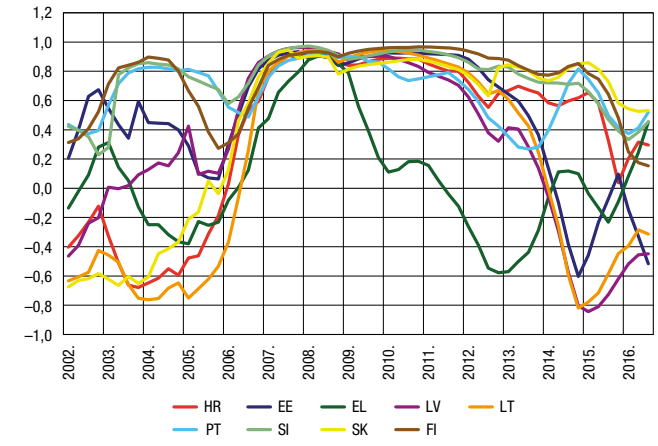

Izvor: HNB

Slika 12. Korelacije ciklusa ostalih zemalja EU-a s ciklusima zemalja jezgre europodručja

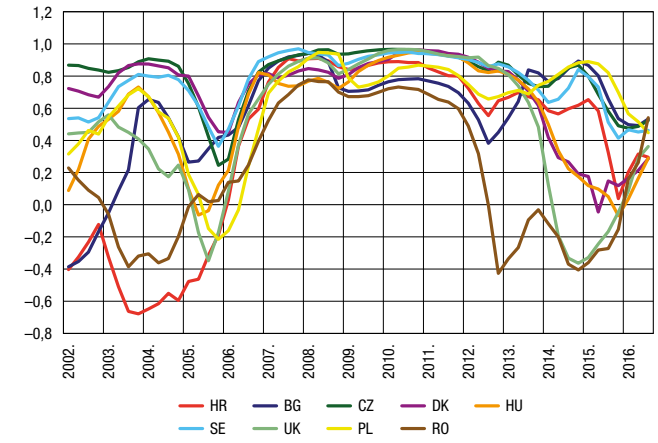

Izvor: HNB

Slika 13. Fazna sinkroniziranost ciklusa rubnih zemalja europodručja (i Hrvatske) s ciklusima zemalja jezgre europodručja

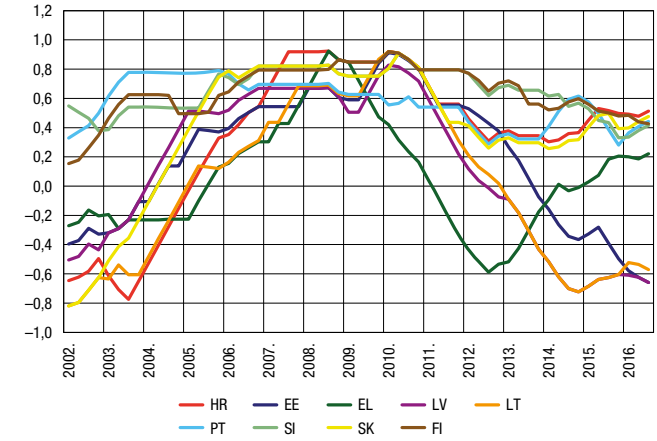

Izvor: HNB

Slika 14. Fazna sinkroniziranost ciklusa ostalih zemalja EU-a s ciklusima zemalja jezgre europodručja

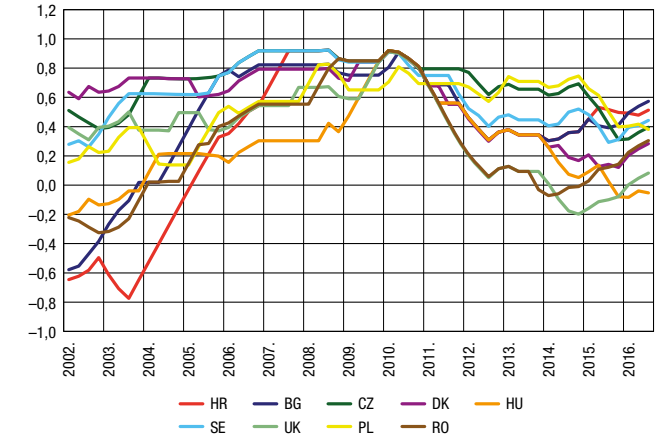

Izvor: HNB

Slika 15. Sličnost ciklusa rubnih zemalja europodručja (i Hrvatske) s ciklusima zemalja jezgre europodručja

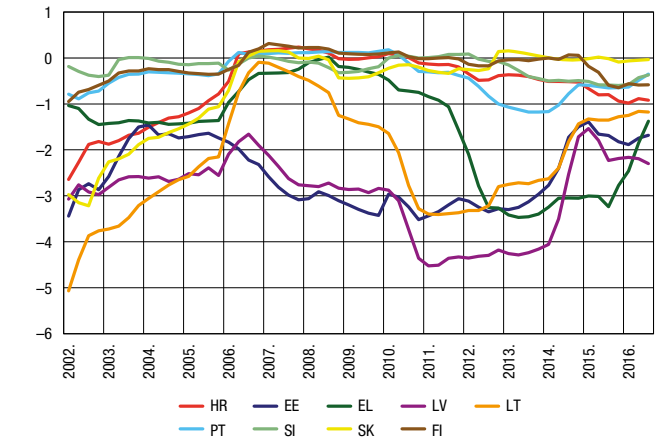

Izvor: HNB

Slika 16. Sličnost ciklusa ostalih zemalja EU-a s ciklusima zemalja jezgre europodručja

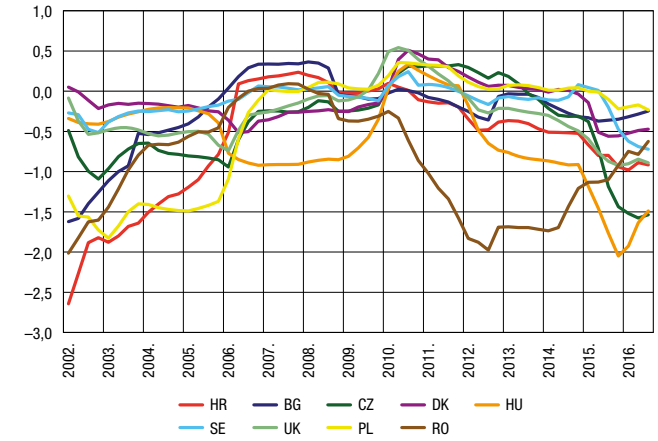

Izvor: HNB

Slika 17. Korelacijski indeks ciklusa rubnih zemalja EU-a s ciklusima zemalja jezgre europodručja prema Cerqueira i Martins (2009.)

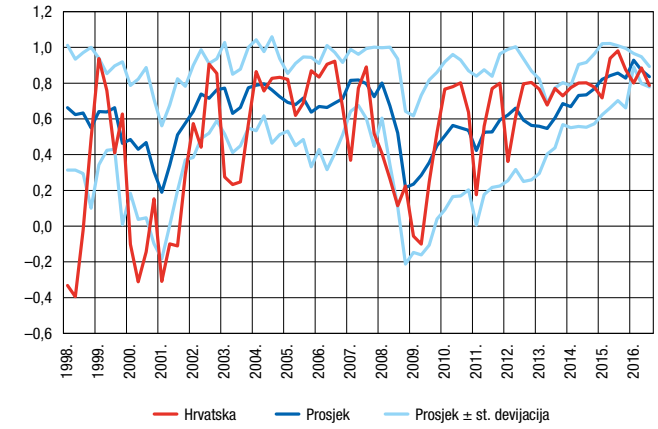

Izvor: HNB

Slika 18. Doprinosi simetričnih šokova BDP-u (rubne zemlje europodručja i Hrvatska)

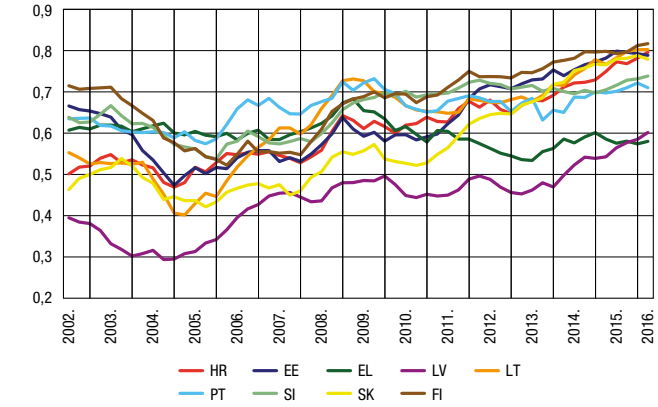

Napomena: Doprinosi simetričnih šokova izračunati su kao postotni udio simetričnih šokova (i šokova monetarne politike) u povijesnoj dekompoziciji tromjesečne stope rasta domaćeg BDP-a. Prikazani su četverogodišnji pomični prosjeci.
Izvor: HNB

Slika 19. Doprinosi simetričnih šokova BDP-u (ostale zemlje EU-a)

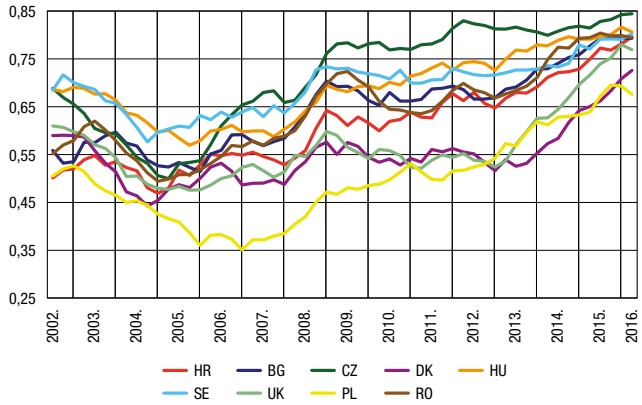

Napomena: Doprinosi simetričnih šokova izračunati su kao postotni udio simetričnih šokova (i šokova monetarne politike) u povijesnoj dekompoziciji tromjesečne stope rasta domaćeg BDP-a. Prikazani su četverogodišnji pomični prosjeci.
Izvor: HNB

Slika 20. Doprinosi šokova koji dovode do simetrične reakcije u BDP-u (rubne zemlje europodručja i Hrvatska)

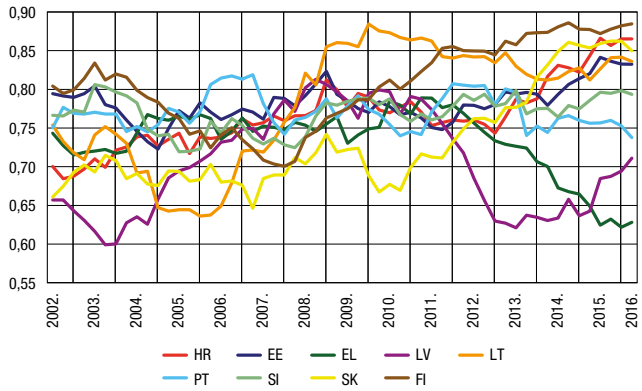

Napomena: Doprinosi simetričnih šokova izračunati su kao postotni udio simetričnih šokova (i šokova monetarne politike) u povijesnoj dekompoziciji tromjesečne stope rasta domaćeg BDP-a. Simetričnim šokovima pribrojeni su i asimetrični šokovi koji dovode do simetrične reakcije BDP-a Hrvatske i europodručja. Prikazani su četverogodišnji pomični prosjeci.
Izvor: HNB

Slika 21. Doprinosi šokova koji dovode do simetrične reakcije u BDP-u (ostale zemlje EU-a)

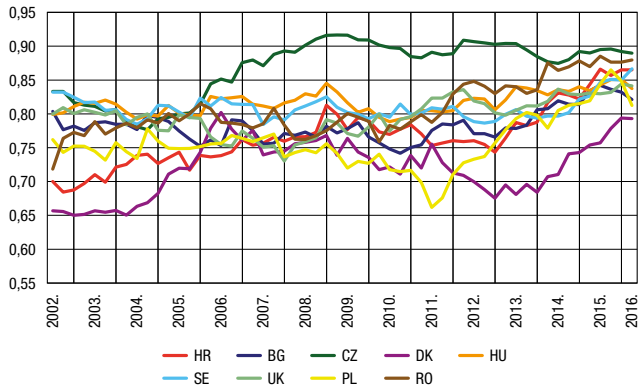

Napomena: Doprinosi simetričnih šokova izračunati su kao postotni udio simetričnih šokova (i šokova monetarne politike) u povijesnoj dekompoziciji tromjesečne stope rasta domaćeg BDP-a. Simetričnim šokovima pribrojeni su i asimetrični šokovi koji dovode do simetrične reakcije BDP-a Hrvatske i europodručja. Prikazani su četverogodišnji pomični prosjeci.
Izvor: HNB

Slika 22. Poslovni ciklusi (odstupanje BDP-a od HP trenda)

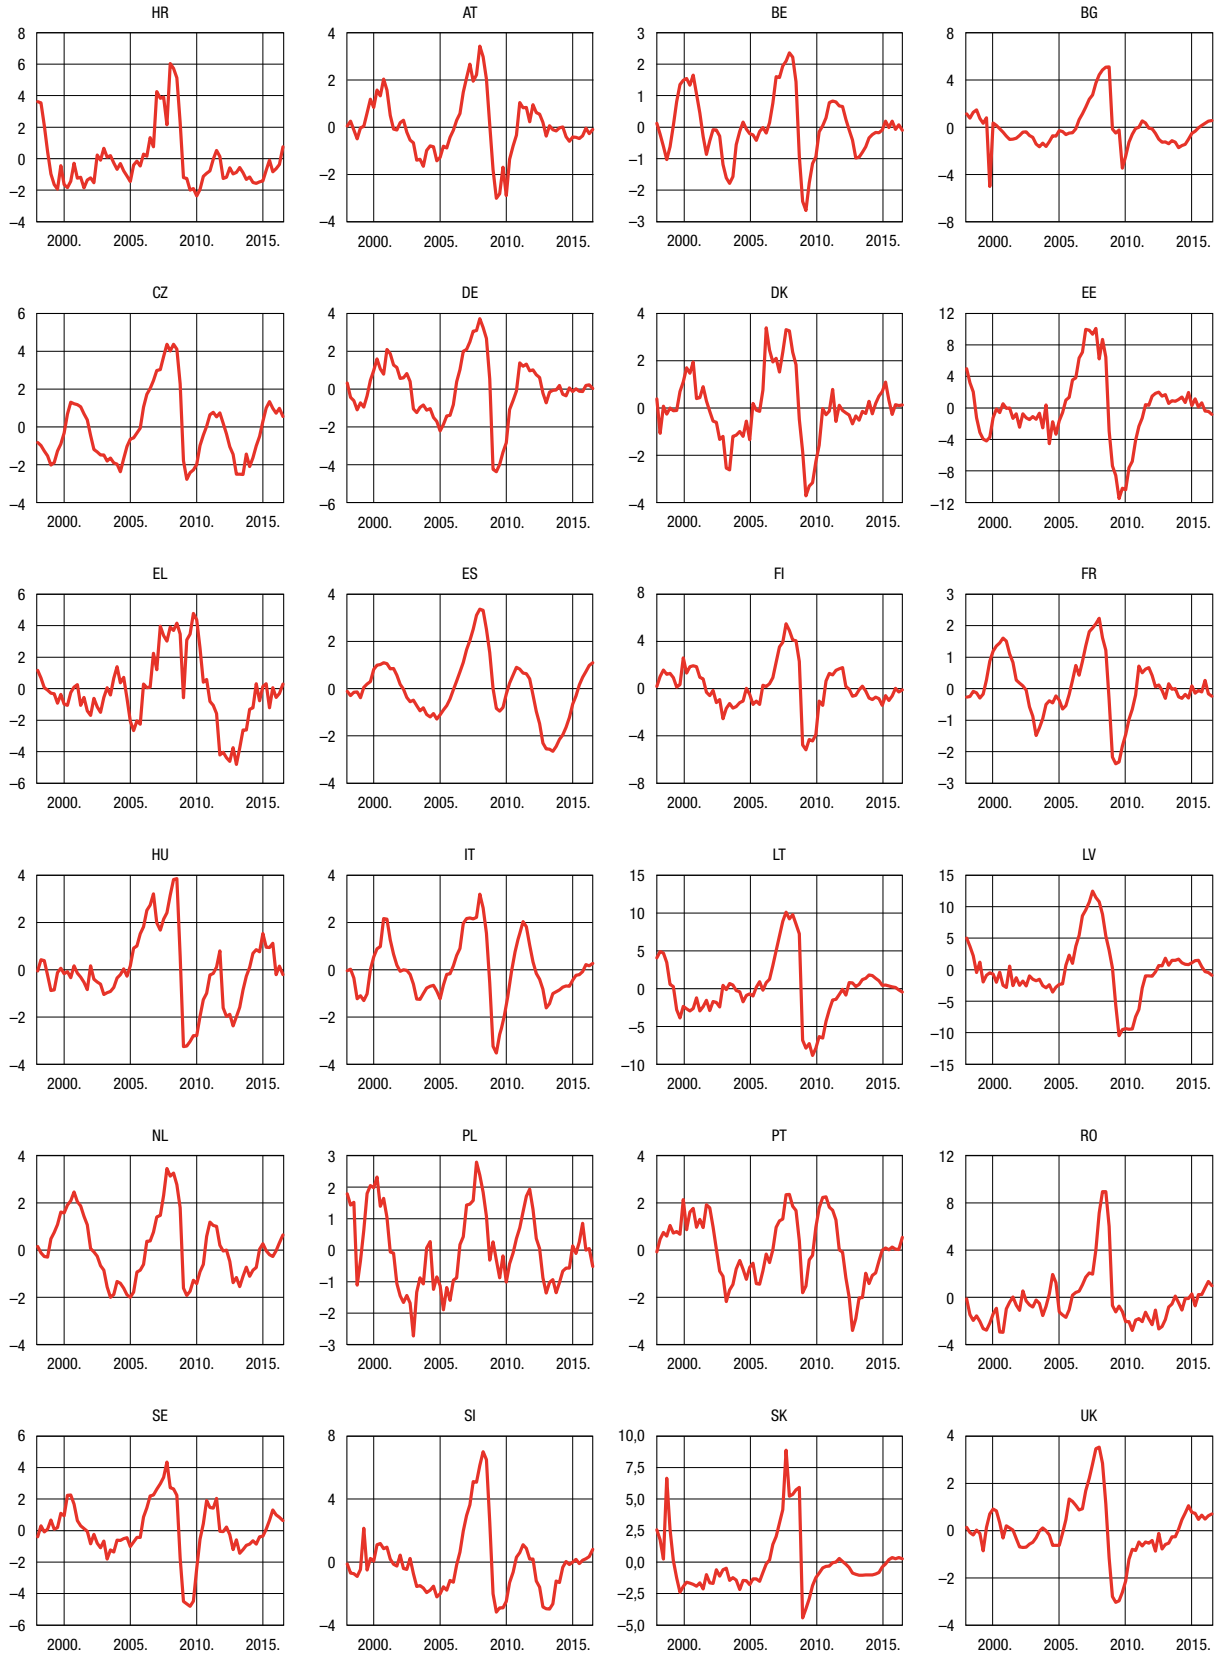

Izvor: HNB

Slika 23. Funkcije impulsnog odziva dobivene iz VAR modela za otvorenu malu ekonomiju – Hrvatsku

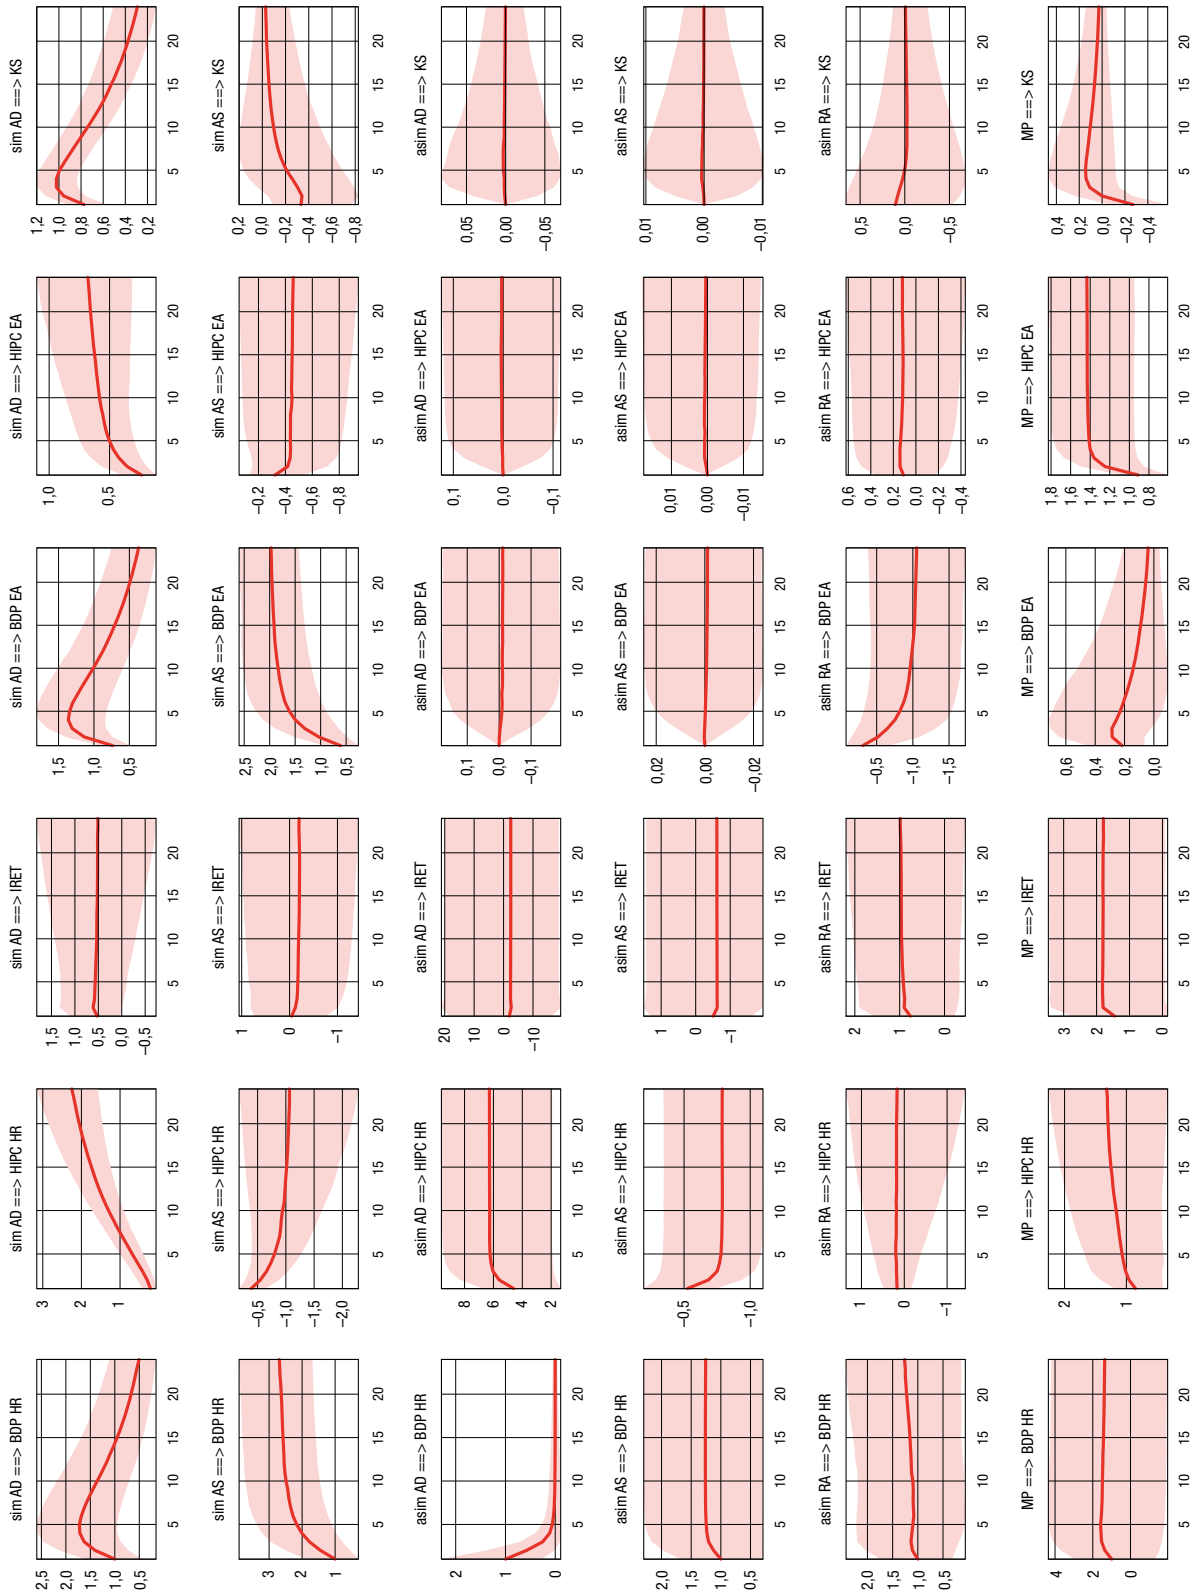

Napomena: Funkcije impulsnog odziva prikazane su u normaliziranom obliku tako da reakcija domaćeg BDP-a u trenutku djelovanja šoka bude 1%. Nadalje, za sve varijable, osim kamatnih stopa, prikazan je kumulativni utjecaj pojedinog šoka. Simetrični šokovi agregatne potražnje i agregatne ponude označeni su sa *sim AD* i *sim AS*, dok su s *asim AD* i *asim AS* označeni idiosinkratski šokovi agregatne potražnje i ponude. Šok asimetrične realne aktivnosti označen je s *asim RA*, a šok monetarne politike ESB-a s *MP*.
Izvor: HNB

Tablica 3. Korelacije ciklusa

	HR	AT	BE	BG	CZ	DE	DK	EE	EL	ES	FI	FR	HU	IT	LT	LV	NL	PL	PT	RO	SE	SI	SK	UK
HR	1,00	0,59	0,45	0,76	0,64	0,54	0,49	0,70	0,44	0,59	0,61	0,46	0,65	0,56	0,80	0,74	0,49	0,42	0,27	0,71	0,50	0,72	0,75	0,60
AT	0,59	1,00	0,87	0,57	0,76	0,91	0,83	0,75	0,06	0,64	0,89	0,93	0,64	0,86	0,63	0,69	0,85	0,66	0,50	0,43	0,83	0,81	0,55	0,73
BE	0,45	0,87	1,00	0,47	0,75	0,81	0,79	0,60	0,16	0,68	0,82	0,90	0,64	0,87	0,45	0,49	0,81	0,72	0,63	0,36	0,86	0,77	0,45	0,71
BG	0,76	0,57	0,47	1,00	0,72	0,53	0,52	0,55	0,42	0,71	0,69	0,48	0,60	0,52	0,72	0,62	0,61	0,45	0,45	0,73	0,52	0,78	0,81	0,50
CZ	0,64	0,76	0,75	0,72	1,00	0,77	0,79	0,68	0,37	0,86	0,75	0,77	0,77	0,84	0,59	0,64	0,81	0,56	0,57	0,65	0,78	0,87	0,64	0,72
DE	0,54	0,91	0,81	0,53	0,77	1,00	0,81	0,75	0,04	0,63	0,87	0,91	0,64	0,90	0,62	0,64	0,83	0,55	0,52	0,46	0,84	0,80	0,57	0,74
DK	0,49	0,83	0,79	0,52	0,79	0,81	1,00	0,76	0,07	0,60	0,78	0,88	0,78	0,79	0,60	0,70	0,77	0,51	0,47	0,41	0,85	0,73	0,52	0,82
EE	0,70	0,75	0,60	0,55	0,68	0,75	0,76	1,00	0,00	0,38	0,72	0,72	0,77	0,67	0,85	0,90	0,50	0,36	0,09	0,50	0,72	0,63	0,60	0,83
EL	0,44	0,06	0,16	0,42	0,37	0,04	0,07	0,00	1,00	0,56	0,11	0,02	0,27	0,17	0,18	0,13	0,30	0,26	0,45	0,53	0,09	0,45	0,40	0,16
ES	0,59	0,64	0,68	0,71	0,86	0,63	0,60	0,38	0,56	1,00	0,65	0,62	0,55	0,75	0,37	0,41	0,84	0,64	0,79	0,55	0,67	0,86	0,58	0,53
FI	0,61	0,89	0,82	0,69	0,75	0,87	0,78	0,72	0,11	0,65	1,00	0,90	0,65	0,82	0,72	0,66	0,82	0,64	0,56	0,47	0,85	0,81	0,71	0,73
FR	0,46	0,93	0,90	0,48	0,77	0,91	0,88	0,72	0,02	0,62	0,90	1,00	0,66	0,89	0,56	0,62	0,84	0,62	0,55	0,36	0,88	0,74	0,48	0,77
HU	0,65	0,64	0,64	0,60	0,77	0,64	0,78	0,77	0,27	0,55	0,65	0,66	1,00	0,69	0,73	0,73	0,56	0,34	0,34	0,63	0,72	0,73	0,58	0,84
IT	0,56	0,86	0,87	0,52	0,84	0,90	0,79	0,67	0,17	0,75	0,82	0,89	0,69	1,00	0,50	0,51	0,81	0,59	0,64	0,40	0,88	0,79	0,49	0,71
LT	0,80	0,63	0,45	0,72	0,59	0,62	0,60	0,85	0,18	0,37	0,72	0,56	0,73	0,50	1,00	0,88	0,45	0,30	0,10	0,67	0,57	0,67	0,81	0,77
LV	0,74	0,69	0,49	0,62	0,64	0,64	0,70	0,90	0,13	0,41	0,66	0,62	0,73	0,51	0,88	1,00	0,50	0,38	0,06	0,58	0,59	0,65	0,65	0,79
NL	0,49	0,85	0,81	0,61	0,81	0,83	0,77	0,50	0,30	0,84	0,82	0,84	0,56	0,81	0,45	0,50	1,00	0,71	0,75	0,45	0,76	0,86	0,56	0,61
PL	0,42	0,66	0,72	0,45	0,56	0,55	0,51	0,36	0,26	0,64	0,64	0,62	0,34	0,59	0,30	0,38	0,71	1,00	0,57	0,20	0,58	0,61	0,38	0,42
PT	0,27	0,50	0,63	0,45	0,57	0,52	0,47	0,09	0,45	0,79	0,56	0,55	0,34	0,64	0,10	0,06	0,75	0,57	1,00	0,22	0,58	0,65	0,39	0,31
RO	0,71	0,43	0,36	0,73	0,65	0,46	0,41	0,50	0,53	0,55	0,47	0,36	0,63	0,40	0,67	0,58	0,45	0,20	0,22	1,00	0,33	0,70	0,65	0,53
SE	0,50	0,83	0,86	0,52	0,78	0,84	0,85	0,72	0,09	0,67	0,85	0,88	0,72	0,88	0,57	0,59	0,76	0,58	0,58	0,33	1,00	0,75	0,56	0,81
SI	0,72	0,81	0,77	0,78	0,87	0,80	0,73	0,63	0,45	0,86	0,81	0,74	0,73	0,79	0,67	0,65	0,86	0,61	0,65	0,70	0,75	1,00	0,73	0,71
SK	0,75	0,55	0,45	0,81	0,64	0,57	0,52	0,60	0,40	0,58	0,71	0,48	0,58	0,49	0,81	0,65	0,56	0,38	0,39	0,65	0,56	0,73	1,00	0,59
UK	0,60	0,73	0,71	0,50	0,72	0,74	0,82	0,83	0,16	0,53	0,73	0,77	0,84	0,71	0,77	0,79	0,61	0,42	0,31	0,53	0,81	0,71	0,59	1,00

Tablica 4. Fazna sinkroniziranost ciklusa

	HR	AT	BE	BG	CZ	DE	DK	EE	EL	ES	FI	FR	HU	IT	LT	LV	NL	PL	PT	RO	SE	SI	SK	UK
HR	1,00	0,28	0,20	0,57	0,33	0,23	0,28	0,28	0,39	0,17	0,36	0,20	0,36	0,36	0,31	0,28	0,28	0,17	0,15	0,44	0,23	0,23	0,63	0,20
AT	0,28	1,00	0,60	0,39	0,36	0,57	0,25	0,25	–0,01	0,47	0,60	0,71	0,17	0,49	0,07	0,15	0,57	0,52	0,33	0,09	0,41	0,52	0,28	0,17
BE	0,20	0,60	1,00	0,47	0,55	0,49	0,39	0,12	0,17	0,60	0,57	0,52	0,20	0,63	–0,12	–0,04	0,60	0,65	0,47	0,17	0,65	0,71	0,36	0,31
BG	0,57	0,39	0,47	1,00	0,39	0,28	0,33	0,12	0,23	0,44	0,52	0,25	0,25	0,41	0,31	0,23	0,49	0,49	0,47	0,44	0,55	0,49	0,79	0,36
CZ	0,33	0,36	0,55	0,39	1,00	0,57	0,63	0,20	0,25	0,68	0,49	0,60	0,33	0,76	0,01	0,15	0,63	0,47	0,49	0,52	0,63	0,68	0,44	0,44
DE	0,23	0,57	0,49	0,28	0,57	1,00	0,57	0,09	–0,07	0,52	0,44	0,65	0,17	0,60	–0,09	–0,01	0,63	0,36	0,44	0,20	0,41	0,63	0,23	0,33
DK	0,28	0,25	0,39	0,33	0,63	0,57	1,00	0,25	0,20	0,47	0,39	0,49	0,44	0,60	0,12	0,25	0,57	0,36	0,33	0,36	0,47	0,47	0,33	0,65
EE	0,28	0,25	0,12	0,12	0,20	0,09	0,25	1,00	0,20	–0,12	0,12	0,17	0,55	0,07	0,60	0,73	–0,01	0,25	–0,20	0,20	0,04	0,04	0,28	0,28
EL	0,39	–0,01	0,17	0,23	0,25	–0,07	0,20	0,20	1,00	0,09	0,07	–0,04	0,28	0,17	0,12	0,20	0,09	0,15	0,07	0,36	0,15	0,15	0,28	0,17
ES	0,17	0,47	0,60	0,44	0,68	0,52	0,47	–0,12	0,09	1,00	0,49	0,55	0,17	0,71	–0,15	–0,07	0,73	0,52	0,71	0,31	0,68	0,68	0,33	0,33
FI	0,36	0,60	0,57	0,52	0,49	0,44	0,39	0,12	0,07	0,49	1,00	0,57	0,09	0,63	0,04	0,07	0,60	0,55	0,47	0,17	0,65	0,49	0,41	0,25
FR	0,20	0,71	0,52	0,25	0,60	0,65	0,49	0,17	–0,04	0,55	0,57	1,00	0,15	0,68	–0,12	0,01	0,60	0,49	0,36	0,28	0,49	0,49	0,15	0,31
HU	0,36	0,17	0,20	0,25	0,33	0,17	0,44	0,55	0,28	0,17	0,09	0,15	1,00	0,20	0,36	0,49	0,23	0,17	0,09	0,39	0,17	0,28	0,36	0,41
IT	0,36	0,49	0,63	0,41	0,76	0,60	0,60	0,07	0,17	0,71	0,63	0,68	0,20	1,00	–0,17	–0,04	0,65	0,49	0,52	0,33	0,71	0,65	0,36	0,36
LT	0,31	0,07	–0,12	0,31	0,01	–0,09	0,12	0,60	0,12	–0,15	0,04	–0,12	0,36	–0,17	1,00	0,76	–0,04	0,01	–0,12	0,23	0,01	–0,04	0,41	0,36
LV	0,28	0,15	–0,04	0,23	0,15	–0,01	0,25	0,73	0,20	–0,07	0,07	0,01	0,49	–0,04	0,76	1,00	0,04	0,04	–0,15	0,31	0,04	–0,01	0,33	0,39
NL	0,28	0,57	0,60	0,49	0,63	0,63	0,57	–0,01	0,09	0,73	0,60	0,60	0,23	0,65	–0,04	0,04	1,00	0,47	0,55	0,25	0,57	0,63	0,33	0,39
PL	0,17	0,52	0,65	0,49	0,47	0,36	0,36	0,25	0,15	0,52	0,55	0,49	0,17	0,49	0,01	0,04	0,47	1,00	0,39	0,20	0,52	0,52	0,44	0,23
PT	0,15	0,33	0,47	0,47	0,49	0,44	0,33	–0,20	0,07	0,71	0,47	0,36	0,09	0,52	–0,12	–0,15	0,55	0,39	1,00	0,12	0,65	0,55	0,36	0,20
RO	0,44	0,09	0,17	0,44	0,52	0,20	0,36	0,20	0,36	0,31	0,17	0,28	0,39	0,33	0,23	0,31	0,25	0,20	0,12	1,00	0,31	0,25	0,55	0,39
SE	0,23	0,41	0,65	0,55	0,63	0,41	0,47	0,04	0,15	0,68	0,65	0,49	0,17	0,71	0,01	0,04	0,57	0,52	0,65	0,31	1,00	0,57	0,39	0,49
SI	0,23	0,52	0,71	0,49	0,68	0,63	0,47	0,04	0,15	0,68	0,49	0,49	0,28	0,65	–0,04	–0,01	0,63	0,52	0,55	0,25	0,57	1,00	0,44	0,33
SK	0,63	0,28	0,36	0,79	0,44	0,23	0,33	0,28	0,28	0,33	0,41	0,15	0,36	0,36	0,41	0,33	0,33	0,44	0,36	0,55	0,39	0,44	1,00	0,31
UK	0,20	0,17	0,31	0,36	0,44	0,33	0,65	0,28	0,17	0,33	0,25	0,31	0,41	0,36	0,36	0,39	0,39	0,23	0,20	0,39	0,49	0,33	0,31	1,00

Tablica 5. Sličnost ciklusa

	HR	AT	BE	BG	CZ	DE	DK	EE	EL	ES	FI	FR	HU	IT	LT	LV	NL	PL	PT	RO	SE	SI	SK	UK
HR	1,00	–0,06	–0,12	0,17	–0,25	–0,27	–0,24	–0,86	–0,30	–0,08	–0,16	–0,12	–0,18	–0,02	–0,48	–0,89	–0,20	–0,22	–0,33	–0,18	–0,25	–0,16	0,10	–0,09
AT	–0,06	1,00	0,58	0,20	0,00	0,52	0,41	–0,86	–0,46	0,29	0,40	0,67	0,01	0,51	–0,81	–1,05	0,48	0,24	0,20	–0,27	0,32	0,26	–0,07	0,23
BE	–0,12	0,58	1,00	0,22	0,09	0,37	0,40	–0,93	–0,38	0,27	0,23	0,67	0,14	0,51	–0,89	–1,16	0,45	0,40	0,28	–0,20	0,35	0,27	–0,09	0,29
BG	0,17	0,20	0,22	1,00	0,07	–0,02	0,07	–1,01	–0,28	0,31	0,11	0,17	–0,05	0,18	–0,65	–1,08	0,23	0,07	0,12	–0,10	0,16	0,21	0,31	0,10
CZ	–0,25	0,00	0,09	0,07	1,00	0,00	0,18	–0,90	–0,52	0,30	–0,11	0,11	0,00	0,24	–1,03	–1,00	0,12	–0,08	–0,05	–0,22	0,24	0,23	–0,16	0,06
DE	–0,27	0,52	0,37	–0,02	0,00	1,00	0,29	–0,92	–0,59	0,16	0,25	0,48	–0,09	0,48	–0,93	–1,15	0,46	0,12	0,13	–0,32	0,17	0,30	–0,14	0,09
DK	–0,24	0,41	0,40	0,07	0,18	0,29	1,00	–0,75	–0,50	0,12	0,11	0,48	0,24	0,33	–0,74	–0,82	0,32	0,05	0,05	–0,33	0,32	0,13	–0,16	0,42
EE	–0,86	–0,86	–0,93	–1,01	–0,90	–0,92	–0,75	1,00	–1,43	–1,30	–1,01	–0,91	–0,65	–1,00	–0,34	–0,15	–1,16	–1,01	–1,44	–1,08	–0,99	–1,03	–0,94	–0,71
EL	–0,30	–0,46	–0,38	–0,28	–0,52	–0,59	–0,50	–1,43	1,00	–0,27	–0,58	–0,44	–0,38	–0,41	–1,07	–1,41	–0,45	–0,38	–0,36	–0,32	–0,53	–0,25	–0,39	–0,37
ES	–0,08	0,29	0,27	0,31	0,30	0,16	0,12	–1,30	–0,27	1,00	0,03	0,33	–0,09	0,39	–1,12	–1,41	0,37	0,07	0,32	–0,15	0,29	0,33	–0,10	0,12
FI	–0,16	0,40	0,23	0,11	–0,11	0,25	0,11	–1,01	–0,58	0,03	1,00	0,32	–0,29	0,26	–0,88	–1,14	0,28	0,18	0,06	–0,52	0,19	0,06	–0,10	–0,11
FR	–0,12	0,67	0,67	0,17	0,11	0,48	0,48	–0,91	–0,44	0,33	0,32	1,00	0,11	0,56	–0,79	–1,10	0,46	0,25	0,26	–0,21	0,34	0,21	–0,12	0,34
HU	–0,18	0,01	0,14	–0,05	0,00	–0,09	0,24	–0,65	–0,38	–0,09	–0,29	0,11	1,00	0,04	–0,71	–0,76	–0,14	–0,20	–0,22	–0,23	0,02	–0,05	–0,30	0,39
IT	–0,02	0,51	0,51	0,18	0,24	0,48	0,33	–1,00	–0,41	0,39	0,26	0,56	0,04	1,00	–0,97	–1,24	0,45	0,20	0,27	–0,22	0,42	0,28	–0,04	0,20
LT	–0,48	–0,81	–0,89	–0,65	–1,03	–0,93	–0,74	–0,34	–1,07	–1,12	–0,88	–0,79	–0,71	–0,97	1,00	–0,29	–1,05	–0,92	–1,22	–0,69	–0,92	–0,93	–0,38	–0,52
LV	–0,89	–1,05	–1,16	–1,08	–1,00	–1,15	–0,82	–0,15	–1,41	–1,41	–1,14	–1,10	–0,76	–1,24	–0,29	1,00	–1,22	–1,20	–1,52	–1,15	–1,16	–1,13	–0,90	–0,83
NL	–0,20	0,48	0,45	0,23	0,12	0,46	0,32	–1,16	–0,45	0,37	0,28	0,46	–0,14	0,45	–1,05	–1,22	1,00	0,25	0,40	–0,30	0,30	0,38	–0,04	0,09
PL	–0,22	0,24	0,40	0,07	–0,08	0,12	0,05	–1,01	–0,38	0,07	0,18	0,25	–0,20	0,20	–0,92	–1,20	0,25	1,00	0,14	–0,46	0,15	0,04	–0,06	–0,03
PT	–0,33	0,20	0,28	0,12	–0,05	0,13	0,05	–1,44	–0,36	0,32	0,06	0,26	–0,22	0,27	–1,22	–1,52	0,40	0,14	1,00	–0,42	0,17	0,22	–0,23	–0,12
RO	–0,18	–0,27	–0,20	–0,10	–0,22	–0,32	–0,33	–1,08	–0,32	–0,15	–0,52	–0,21	–0,23	–0,22	–0,69	–1,15	–0,30	–0,46	–0,42	1,00	–0,34	–0,14	–0,20	–0,10
SE	–0,25	0,32	0,35	0,16	0,24	0,17	0,32	–0,99	–0,53	0,29	0,19	0,34	0,02	0,42	–0,92	–1,16	0,30	0,15	0,17	–0,34	1,00	0,14	–0,09	0,28
SI	–0,16	0,26	0,27	0,21	0,23	0,30	0,13	–1,03	–0,25	0,33	0,06	0,21	–0,05	0,28	–0,93	–1,13	0,38	0,04	0,22	–0,14	0,14	1,00	0,03	0,04
SK	0,10	–0,07	–0,09	0,31	–0,16	–0,14	–0,16	–0,94	–0,39	–0,10	–0,10	–0,12	–0,30	–0,04	–0,38	–0,90	–0,04	–0,06	–0,23	–0,20	–0,09	0,03	1,00	–0,14
UK	–0,09	0,23	0,29	0,10	0,06	0,09	0,42	–0,71	–0,37	0,12	–0,11	0,34	0,39	0,20	–0,52	–0,83	0,09	–0,03	–0,12	–0,10	0,28	0,04	–0,14	1,00

Tablica 6. Korelacije šokova ponude

	HR	AT	BE	BG	CZ	DE	DK	EE	EL	ES	FI	FR	HU	IT	LT	LV	NL	PL	PT	RO	SE	SI	SK	UK
HR	1,00	0,28	0,20	0,05	0,19	0,24	0,13	0,14	0,16	0,18	0,07	0,30	0,34	0,21	0,21	0,11	0,10	0,21	0,14	0,25	0,07	0,21	0,03	0,17
AT	0,28	1,00	0,48	0,07	0,09	0,35	0,15	0,03	0,14	0,09	0,20	0,47	0,22	0,30	0,12	–0,05	0,24	0,39	0,14	0,17	0,10	0,22	0,03	0,24
BE	0,20	0,48	1,00	0,05	0,12	0,18	0,09	0,26	0,10	0,19	0,20	0,44	0,30	0,35	–0,02	–0,09	0,18	0,46	0,21	0,11	0,16	0,20	–0,10	0,29
BG	0,05	0,07	0,05	1,00	0,33	0,22	0,02	0,06	0,14	0,19	0,39	0,06	0,15	0,03	0,51	–0,01	0,23	0,02	0,26	0,40	0,05	0,22	0,39	–0,05
CZ	0,19	0,09	0,12	0,33	1,00	0,46	0,17	0,43	0,29	0,20	0,44	0,43	0,48	0,10	0,56	0,20	0,56	0,06	0,34	0,33	0,42	0,45	0,43	–0,04
DE	0,24	0,35	0,18	0,22	0,46	1,00	0,20	0,26	0,31	0,14	0,54	0,52	0,37	0,25	0,49	0,15	0,50	0,20	0,19	0,36	0,41	0,37	0,35	0,29
DK	0,13	0,15	0,09	0,02	0,17	0,20	1,00	0,02	–0,01	0,25	0,23	0,25	0,22	0,26	0,20	0,07	0,38	0,09	0,21	–0,01	0,31	0,15	0,30	0,07
EE	0,14	0,03	0,26	0,06	0,43	0,26	0,02	1,00	0,11	0,02	0,09	0,20	0,35	–0,02	0,14	0,20	0,21	0,27	0,07	0,22	0,50	0,26	0,02	0,12
EL	0,16	0,14	0,10	0,14	0,29	0,31	–0,01	0,11	1,00	0,13	0,34	0,31	0,17	0,39	0,42	0,17	0,38	–0,09	0,18	0,36	0,19	0,13	0,26	0,08
ES	0,18	0,09	0,19	0,19	0,20	0,14	0,25	0,02	0,13	1,00	0,30	0,30	0,22	0,34	0,28	0,20	0,32	0,11	0,49	0,09	0,14	0,26	0,24	0,33
FI	0,07	0,20	0,20	0,39	0,44	0,54	0,23	0,09	0,34	0,30	1,00	0,44	0,21	0,24	0,61	0,16	0,51	0,18	0,49	0,37	0,35	0,26	0,58	0,13
FR	0,30	0,47	0,44	0,06	0,43	0,52	0,25	0,20	0,31	0,30	0,44	1,00	0,32	0,50	0,38	0,20	0,33	0,38	0,30	0,24	0,20	0,17	0,19	0,32
HU	0,34	0,22	0,30	0,15	0,48	0,37	0,22	0,35	0,17	0,22	0,21	0,32	1,00	0,05	0,29	0,19	0,32	0,19	0,21	0,38	0,30	0,33	0,18	0,11
IT	0,21	0,30	0,35	0,03	0,10	0,25	0,26	–0,02	0,39	0,34	0,24	0,50	0,05	1,00	0,07	0,19	0,23	0,17	0,37	0,13	0,19	0,10	0,05	0,17
LT	0,21	0,12	–0,02	0,51	0,56	0,49	0,20	0,14	0,42	0,28	0,61	0,38	0,29	0,07	1,00	0,29	0,54	–0,02	0,24	0,35	0,21	0,29	0,59	0,09
LV	0,11	–0,05	–0,09	–0,01	0,20	0,15	0,07	0,20	0,17	0,20	0,16	0,20	0,19	0,19	0,29	1,00	0,22	0,02	0,07	0,07	0,23	0,08	0,17	0,01
NL	0,10	0,24	0,18	0,23	0,56	0,50	0,38	0,21	0,38	0,32	0,51	0,33	0,32	0,23	0,54	0,22	1,00	0,10	0,49	0,32	0,48	0,26	0,43	0,13
PL	0,21	0,39	0,46	0,02	0,06	0,20	0,09	0,27	–0,09	0,11	0,18	0,38	0,19	0,17	–0,02	0,02	0,10	1,00	0,01	0,04	0,18	0,04	–0,10	0,20
PT	0,14	0,14	0,21	0,26	0,34	0,19	0,21	0,07	0,18	0,49	0,49	0,30	0,21	0,37	0,24	0,07	0,49	0,01	1,00	0,15	0,34	0,23	0,27	0,10
RO	0,25	0,17	0,11	0,40	0,33	0,36	–0,01	0,22	0,36	0,09	0,37	0,24	0,38	0,13	0,35	0,07	0,32	0,04	0,15	1,00	0,25	0,02	0,32	0,04
SE	0,07	0,10	0,16	0,05	0,42	0,41	0,31	0,50	0,19	0,14	0,35	0,20	0,30	0,19	0,21	0,23	0,48	0,18	0,34	0,25	1,00	0,27	0,33	0,20
SI	0,21	0,22	0,20	0,22	0,45	0,37	0,15	0,26	0,13	0,26	0,26	0,17	0,33	0,10	0,29	0,08	0,26	0,04	0,23	0,02	0,27	1,00	0,31	–0,08
SK	0,03	0,03	–0,10	0,39	0,43	0,35	0,30	0,02	0,26	0,24	0,58	0,19	0,18	0,05	0,59	0,17	0,43	–0,10	0,27	0,32	0,33	0,31	1,00	–0,07
UK	0,17	0,24	0,29	–0,05	–0,04	0,29	0,07	0,12	0,08	0,33	0,13	0,32	0,11	0,17	0,09	0,01	0,13	0,20	0,10	0,04	0,20	–0,08	–0,07	1,00

Tablica 7. Korelacije šokova potražnje

	HR	AT	BE	BG	CZ	DE	DK	EE	EL	ES	FI	FR	HU	IT	LT	LV	NL	PL	PT	RO	SE	SI	SK	UK
HR	1,00	0,48	0,53	0,48	0,28	0,48	0,52	0,48	0,44	0,56	0,39	0,58	0,47	0,58	0,25	0,26	0,45	0,35	0,40	0,15	0,41	0,61	0,19	0,50
AT	0,48	1,00	0,67	0,24	0,36	0,67	0,53	0,62	0,52	0,51	0,56	0,61	0,16	0,44	0,34	0,24	0,47	0,17	0,53	–0,01	0,40	0,39	0,13	0,60
BE	0,53	0,67	1,00	0,42	0,42	0,69	0,56	0,70	0,61	0,55	0,62	0,68	0,47	0,62	0,36	0,26	0,47	0,34	0,50	0,13	0,43	0,49	0,08	0,57
BG	0,48	0,24	0,42	1,00	0,34	0,33	0,43	0,39	0,38	0,35	0,34	0,40	0,40	0,43	0,30	0,22	0,15	0,12	0,26	0,11	0,24	0,44	0,39	0,34
CZ	0,28	0,36	0,42	0,34	1,00	0,49	0,46	0,46	0,29	0,30	0,52	0,44	0,36	0,40	0,38	0,06	0,32	0,32	0,36	0,27	0,27	0,36	0,15	0,22
DE	0,48	0,67	0,69	0,33	0,49	1,00	0,56	0,61	0,55	0,64	0,65	0,76	0,34	0,48	0,49	0,23	0,65	0,32	0,60	0,17	0,48	0,45	0,32	0,60
DK	0,52	0,53	0,56	0,43	0,46	0,56	1,00	0,57	0,47	0,60	0,64	0,64	0,45	0,52	0,51	0,30	0,45	0,37	0,60	0,19	0,62	0,46	0,37	0,51
EE	0,48	0,62	0,70	0,39	0,46	0,61	0,57	1,00	0,49	0,66	0,59	0,63	0,30	0,56	0,49	0,21	0,44	0,27	0,40	0,29	0,58	0,48	0,12	0,50
EL	0,44	0,52	0,61	0,38	0,29	0,55	0,47	0,49	1,00	0,53	0,52	0,64	0,39	0,52	0,29	0,13	0,33	0,25	0,43	0,16	0,46	0,42	0,16	0,34
ES	0,56	0,51	0,55	0,35	0,30	0,64	0,60	0,66	0,53	1,00	0,51	0,69	0,32	0,59	0,44	0,09	0,46	0,28	0,54	0,32	0,45	0,44	0,14	0,57
FI	0,39	0,56	0,62	0,34	0,52	0,65	0,64	0,59	0,52	0,51	1,00	0,62	0,35	0,46	0,43	0,10	0,50	0,26	0,55	0,18	0,57	0,31	0,10	0,42
FR	0,58	0,61	0,68	0,40	0,44	0,76	0,64	0,63	0,64	0,69	0,62	1,00	0,39	0,66	0,39	0,15	0,48	0,30	0,62	0,12	0,62	0,53	0,22	0,64
HU	0,47	0,16	0,47	0,40	0,36	0,34	0,45	0,30	0,39	0,32	0,35	0,39	1,00	0,50	0,17	0,17	0,32	0,47	0,36	0,25	0,29	0,47	0,26	0,30
IT	0,58	0,44	0,62	0,43	0,40	0,48	0,52	0,56	0,52	0,59	0,46	0,66	0,50	1,00	0,21	0,05	0,36	0,27	0,44	0,19	0,31	0,58	0,17	0,48
LT	0,25	0,34	0,36	0,30	0,38	0,49	0,51	0,49	0,29	0,44	0,43	0,39	0,17	0,21	1,00	0,36	0,20	0,16	0,35	0,11	0,46	0,19	0,24	0,35
LV	0,26	0,24	0,26	0,22	0,06	0,23	0,30	0,21	0,13	0,09	0,10	0,15	0,17	0,05	0,36	1,00	0,12	0,29	0,13	–0,11	0,28	0,21	0,17	0,21
NL	0,45	0,47	0,47	0,15	0,32	0,65	0,45	0,44	0,33	0,46	0,50	0,48	0,32	0,36	0,20	0,12	1,00	0,23	0,58	0,11	0,46	0,40	0,29	0,45
PL	0,35	0,17	0,34	0,12	0,32	0,32	0,37	0,27	0,25	0,28	0,26	0,30	0,47	0,27	0,16	0,29	0,23	1,00	0,30	0,12	0,16	0,43	0,02	0,19
PT	0,40	0,53	0,50	0,26	0,36	0,60	0,60	0,40	0,43	0,54	0,55	0,62	0,36	0,44	0,35	0,13	0,58	0,30	1,00	0,13	0,43	0,38	0,26	0,47
RO	0,15	–0,01	0,13	0,11	0,27	0,17	0,19	0,29	0,16	0,32	0,18	0,12	0,25	0,19	0,11	–0,11	0,11	0,12	0,13	1,00	0,14	0,05	0,17	–0,07
SE	0,41	0,40	0,43	0,24	0,27	0,48	0,62	0,58	0,46	0,45	0,57	0,62	0,29	0,31	0,46	0,28	0,46	0,16	0,43	0,14	1,00	0,42	0,34	0,34
SI	0,61	0,39	0,49	0,44	0,36	0,45	0,46	0,48	0,42	0,44	0,31	0,53	0,47	0,58	0,19	0,21	0,40	0,43	0,38	0,05	0,42	1,00	0,23	0,47
SK	0,19	0,13	0,08	0,39	0,15	0,32	0,37	0,12	0,16	0,14	0,10	0,22	0,26	0,17	0,24	0,17	0,29	0,02	0,26	0,17	0,34	0,23	1,00	0,25
UK	0,50	0,60	0,57	0,34	0,22	0,60	0,51	0,50	0,34	0,57	0,42	0,64	0,30	0,48	0,35	0,21	0,45	0,19	0,47	–0,07	0,34	0,47	0,25	1,00

Do sada objavljena Istraživanja

Broj	Datum	Naslov	Autor(i)
I-1	studeni 1999.	Je li neslužbeno gospodarstvo izvor korupcije?	Michael Faulend i Vedran Šošić
I-2	ožujak 2000.	Visoka razina cijena u Hrvatskoj – neki uzroci i posljedice	Danijel Nestić
I-3	svibanj 2000.	Statističko evidentiranje pozicije putovanja – turizam u platnoj bilanci Republike Hrvatske	Davor Galinec
I-4	lipanj 2000.	Hrvatska u drugoj fazi tranzicije 1994. – 1999.	Velimir Šonje i Boris Vujčić
I-5	lipanj 2000.	Mjerenje sličnosti gospodarskih kretanja u Srednjoj Europi: povezanost poslovnih ciklusa Njemačke, Mađarske, Češke i Hrvatske	Velimir Šonje i Igeta Vrbanc
I-6	rujan 2000.	Tečaj i proizvodnja nakon velike ekonomske krize i tijekom tranzicijskog razdoblja u Srednjoj Europi	Velimir Šonje
I-7	rujan 2000.	OLS model fizičkih pokazatelja inozemnoga turističkog prometa na hrvatskom tržištu	Tihomir Stučka
I-8	prosinac 2000.	Je li Srednja Europa optimalno valutno područje?	Alen Belullo, Velimir Šonje i Igeta Vrbanc
I-9	svibanj 2001.	Nelikvidnost: razotkrivanje tajne	Velimir Šonje, Michael Faulend i Vedran Šošić
I-10	rujan 2001.	Analiza pristupa Republike Hrvatske Svjetskoj trgovinskoj organizaciji upotrebom računalnog modela opće ravnoteže	Jasminka Šohinger, Davor Galinec i Glenn W. Harrison
I-11	travanj 2002.	Usporedba dvaju ekonometrijskih modela (OLS i SUR) za prognoziranje dolazaka turista u Hrvatsku	Tihomir Stučka
I-12	veljača 2003.	Strane banke u Hrvatskoj: iz druge perspektive	Evan Kraft
I-13	veljača 2004.	Valutna kriza: teorija i praksa s primjenom na Hrvatsku	Ivo Krznar
I-14	lipanj 2004.	Privatizacija, ulazak stranih banaka i efikasnost banaka u Hrvatskoj: analiza stohastičke granice fleksibilne Fourierove funkcije troška	Evan Kraft, Richard Hofler i James Payne
I-15	rujan 2004.	Konvergencija razina cijena: Hrvatska, tranzicijske zemlje i EU	Danijel Nestić
I-16	rujan 2004.	Novi kompozitni indikatori za hrvatsko gospodarstvo: prilog razvoju domaćeg sustava cikličkih indikatora	Saša Cerovac
I-17	siječanj 2006.	Anketa pouzdanja potrošača u Hrvatskoj	Maja Bukovšak
I-18	listopad 2006.	Kratkoročno prognoziranje inflacije u Hrvatskoj korištenjem sezonskih ARIMA procesa	Andreja Pufnik i Davor Kunovac
I-19	svibanj 2007.	Kolika je konkurencija u hrvatskom bankarskom sektoru?	Evan Kraft
I-20	lipanj 2008.	Primjena hedonističke metode za izračunavanje indeksa cijena nekretnina u Hrvatskoj	Davor Kunovac, Enes Đozović, Gorana Lukinić, Andreja Pufnik
I-21	srpanj 2008.	Modeliranje gotovog novca izvan banaka u Hrvatskoj	Maroje Lang, Davor Kunovac, Silvio Basač, Željka Štaudinger
I-22	listopad 2008.	Međunarodni poslovni ciklusi u uvjetima nesavršenosti na tržištu dobara i faktora proizvodnje	Ivo Krznar
I-23	siječanj 2009.	Rizik bankovne zaraze u Hrvatskoj	Marko Krznar
I-24	kolovoz 2009.	Optimalne međunarodne pričuve HNB-a s endogenom vjerojatnošću krize	Ana Maria Čeh i Ivo Krznar
I-25	veljača 2010.	Utjecaj financijske krize i reakcija monetarne politike u Hrvatskoj	Nikola Bokan, Lovorka Grgurić, Ivo Krznar, Maroje Lang
I-26	veljača 2010.	Priljev kapitala i učinkovitost sterilizacije – ocjena koeficijenta sterilizacije i ofset koeficijenta	Igor Ljubaj, Ana Martinis, Marko Mrkalj
I-27	travanj 2010.	Postojanost navika i međunarodne korelacije	Alexandre Dmitriev i Ivo Krznar
I-28	studeni 2010.	Utjecaj vanjskih šokova na domaću inflaciju i BDP	Ivo Krznar i Davor Kunovac
I-29	prosinac 2010.	Dohodovna i cjenovna elastičnost hrvatske robne razmjene – analiza panel-podataka	Vida Bobić
I-30	siječanj 2011.	Model neravnoteže na tržištu kredita i razdoblje kreditnog loma	Ana Maria Čeh, Mirna Dumičić, Ivo Krznar
I-31	travanj 2011.	Analiza kretanja domaće stope inflacije i Phillipsova krivulja	Ivo Krznar
I-32	svibanj 2011.	Identifikacija razdoblja recesija i ekspanzija u Hrvatskoj	Ivo Krznar
I-33	listopad 2011.	Globalna kriza i kreditna euroizacija u Hrvatskoj	Tomislav Galac

Broj	Datum	Naslov	Autor(i)
I-34	studeni 2011.	Središnja banka kao krizni menadžer u Hrvatskoj – analiza hipotetičnih scenarija	Tomislav Galac
I-35	siječanj 2012.	Ocjena utjecaja monetarne politike na kredite stanovništvu i poduzećima: FAVEC pristup	Igor Ljubaj
I-36	ožujak 2012.	Jesu li neke banke blaže od drugih u primjeni pravila klasifikacije plasmana	Tomislav Ridzak
I-37	veljača 2012.	Procjena matrica kreditnih migracija pomoću agregatnih podataka – bajesovski pristup	Davor Kunovac
I-38	svibanj 2012.	Procjena potencijalnog outputa u Republici Hrvatskoj primjenom multivarijantnog filtra	Nikola Bokan i Rafael Ravnik
I-39	listopad 2012.	Način na koji poduzeća u Hrvatskoj određuju i mijenjaju cijene svojih proizvoda: rezultati ankete poduzeća i usporedba s eurozonom	Andreja Pufnik i Davor Kunovac
I-40	ožujak 2013.	Financijski uvjeti i gospodarska aktivnost	Mirna Dumičić i Ivo Krznar
I-41	travanj 2013.	Trošak zaduživanja odabranih zemalja Europske unije i Hrvatske – uloga prelijevanja vanjskih šokova	Davor Kunovac
I-42	lipanj 2014.	Brza procjena BDP-a upotrebom dostupnih mjesečnih indikatora	Davor Kunovac, Borna Špalat
I-43	lipanj 2014.	Pokazatelji financijskog stresa za male otvorene visokoeuroizirane zemlje – primjer Hrvatske	Mirna Dumičić
I-44	srpanj 2014.	Kratkoročne prognoze BDP-a u uvjetima strukturnih promjena	Rafael Ravnik
I-45	srpanj 2015.	Mikroekonomski aspekti utjecaja globalne krize na rast nefinancijskih poduzeća u RH	Tomislav Galac
I-46	rujan 2015.	Pokazatelji financijske stabilnosti – primjer Hrvatske	Mirna Dumičić
I-47	veljača 2017.	Odgođeni oporavak kreditne aktivnosti u Hrvatskoj: uzrokovan ponudom ili potražnjom?	Mirna Dumičić i Igor Ljubaj
I-48	travanj 2017.	Učinkovitost makroprudencijalnih politika u zemljama Srednje i Istočne Europe	Mirna Dumičić
I-49	rujan 2017.	Struktura tokova kapitala i devizni tečaj: Primjer Hrvatske	Maja Bukovšak, Gorana Lukinić Čardić, Nina Ranilović
I-50	rujan 2017.	Primjena gravitacijskog modela u analizi utjecaja ekonomske integracije na hrvatsku robnu razmjenu	Nina Ranilović

Upute autorima

Hrvatska narodna banka objavljuje u svojim povremenim publikacijama Istraživanja, Pregledi i Tehničke bilješke znanstvene i stručne radove zaposlenika Banke i vanjskih suradnika.

Prispjeli radovi podliježu postupku recenzije i klasifikacije koji provodi Komisija za klasifikaciju i vrednovanje radova. Autori se u roku od najviše dva mjeseca od primitka njihova rada obavještavaju o odluci o prihvaćanju ili odbijanju članka za objavljivanje.

Radovi se primaju i objavljuju na hrvatskom i/ili na engleskom jeziku.

Radovi predloženi za objavljivanje moraju ispunjavati sljedeće uvjete.

Tekstovi moraju biti dostavljeni elektroničkom poštom ili optičkim medijima (CD, DVD), a mediju treba priložiti i ispis na papiru. Zapis treba biti u formatu Microsoft Word.

Na prvoj stranici rada obvezno je navesti naslov rada, ime i prezime autora, akademske titule, naziv ustanove u kojoj je autor zaposlen, suradnike te potpunu adresu na koju će se autoru slati primjerci za korekturu.

Dodatne informacije, primjerice zahvale i priznanja, poželjno je uključiti u tekst na kraju uvodnog dijela.

Na drugoj stranici svaki rad mora sadržavati sažetak i ključne riječi. Sažetak mora biti jasan, deskriptivan, pisan u trećem licu i ne dulji od 250 riječi (najviše 1500 znakova). Ispod sažetka treba navesti do 5 ključnih pojmova.

Tekst treba biti otipkan s proredom, na stranici formata A4. Tekst se ne smije oblikovati, dopušteno je samo podebljavanje (bold) i kurziviranje (italic) dijelova teksta. Naslove je potrebno numerirati i odvojiti dvostrukim proredom od teksta, ali bez formatiranja.

Tablice, slike i grafikoni koji su sastavni dio rada, moraju biti pregledni, te moraju sadržavati broj, naslov, mjerne jedinice, legendu, izvor podataka te bilješke. Bilješke koje se odnose na tablice, slike ili grafikone treba obilježiti malim slovima (a, b, c…) i ispisati ih odmah ispod. Ako se posebno dostavljaju (tablice, slike i grafikoni), potrebno je označiti mjesta u tekstu gdje dolaze. Numeracija mora biti u skladu s njihovim slijedom u tekstu te se na njih treba referirati prema numeraciji. Ako su već umetnuti u tekst iz nekih drugih programa, onda je potrebno dostaviti i te datoteke u formatu Excel (grafikoni moraju imati pripadajuće serije podataka).

Ilustracije trebaju biti u standardnom formatu EPS ili TIFF s opisima u Helvetici (Arial, Swiss) veličine 8 točaka. Skenirane ilustracije trebaju biti rezolucije 300 dpi za sivu skalu ili ilustraciju u punoj boji i 600 dpi za lineart (nacrti, dijagrami, sheme).

Formule moraju biti napisane čitljivo. Indeksi i eksponenti moraju biti jasni. Značenja simbola moraju se objasniti odmah nakon jednadžbe u kojoj se prvi put upotrebljavaju. Jednadžbe na koje se autor poziva u tekstu potrebno je obilježiti serijskim brojevima u zagradi uz desnu marginu.

Bilješke na dnu stranice treba označiti arapskim brojkama podignutima iznad teksta. Trebaju biti što kraće i pisane slovima manjima od slova kojima je pisan tekst.

Popis literature dolazi na kraju rada, a u njega ulaze djela navedena u tekstu. Literatura treba biti navedena abecednim redom prezimena autora, a podaci o djelu moraju sadržavati i podatke o izdavaču, mjesto i godinu izdavanja.

Uredništvo zadržava pravo da autoru vrati na ponovni pregled prihvaćeni rad i ilustracije koje ne zadovoljavaju navedene upute.

Pozivamo zainteresirane autore koji žele objaviti svoje radove da ih pošalju na adresu Direkcije za izdavačku djelatnost, prema navedenim uputama.

Hrvatska narodna banka izdaje sljedeće publikacije:

Godišnje izvješće Hrvatske narodne banke
Redovita godišnja publikacija koja sadržava godišnji pregled novčanih i općih ekonomskih kretanja te pregled statistike.

Polugodišnje izvješće Hrvatske narodne banke
Redovita polugodišnja publikacija koja sadržava polugodišnji pregled novčanih i općih ekonomskih kretanja te pregled statistike.

Tromjesečno izvješće Hrvatske narodne banke
Redovita tromjesečna publikacija koja sadržava tromjesečni pregled novčanih i općih ekonomskih kretanja.

Bilten o bankama
Redovita publikacija koja sadržava pregled i podatke o bankama.

Bilten Hrvatske narodne banke
Redovita mjesečna publikacija koja sadržava mjesečni pregled novčanih i općih ekonomskih kretanja te pregled monetarne statistike.

Istraživanja Hrvatske narodne banke
Povremena publikacija u kojoj se objavljuju kraći znanstveni radovi zaposlenika Banke i vanjskih suradnika.

Pregledi Hrvatske narodne banke
Povremena publikacija u kojoj se objavljuju stručni radovi zaposlenika Banke i vanjskih suradnika.

Tehničke bilješke
Povremena publikacija u kojoj se objavljuju informativni radovi zaposlenika Banke i vanjskih suradnika.

Hrvatska narodna banka izdaje i druge publikacije: numizmatička izdanja, brošure, publikacije na drugim medijima (CD-ROM, DVD), knjige, monografije i radove od posebnog interesa za Banku, zbornike radova s konferencija kojih je organizator ili suorganizator Banka, edukativne materijale i druga slična izdanja.

ISSN 1334-0077 (online)