

Velimir Šonje i
Igeta Vrbanc*

UDK 339.7:331.6(4)(497.5)
Izvorni znanstveni rad

MJERENJE SLIČNOSTI GOSPODARSKIH KRETANJA U SREDNJOJ EUROPI: POVEZANOST POSLOVNIH CIKLUSA NJEMAČKE, MAĐARSKE, ČEŠKE I HRVATSKE¹

Autori su u radu određivali relaciju Hrvatske prema njemačkom gospodarstvu i učinili usporedbu sa dvjema naprednijim tranzicijskim zemljama u razdoblju 1992.-1999. Usporedba gospodarstva provedena je usporedbom poslovnih ciklusa predočenih ciklusom nezaposlenosti u Njemačkoj, Mađarskoj, Češkoj i Hrvatskoj. Tom svojom analizom pokazali su da postoji uska povezanost cikličkoga kretanja nezaposlenosti u sve tri zemlje s cikličkim kretanjima nezaposlenosti u Njemačkoj. Najvažniji domet tih istraživanja jest to što je već poznatim rezultatima o uskoj povezanosti cikličkih kretanja u Srednjoj Europi sada pridodan i nalaz za Hrvatsku.

Uvod

Međunarodna koordiniranost poslovnih ciklusa jedan je od najvažnijih preduvjeta za ulazak zemlje u monetarnu uniju. Zemlja koja se odriče nacionalne valute ili mogućnosti manipuliranja njezinom vrijednošću neće izgubiti mogućnost anticikličkog djelovanja monetarnom politikom, ako u monetarnoj uniji ili u međunarodnom sustavu fiksnih tečajeva postoji sklad cikličkih kretanja (Mundell, 1961.). Osim toga, postoje zemlje u kojima slabljenje valute promiče recesijske impulse zbog izostanka kulture stabilnosti i povjerenja, pa takve zemlje fiksiranjem tečaja ili ulaskom u monetarnu uniju tek stvaraju preduvjete za anticikličko djelovanje monetarne politike (Hausmann i sur., 1999; Calvo, 1999.).

* V. Šonje, magistar znanosti, član Uprave Raiffeisen Bank, Zagreb. I. Vrbanc, magistar znanosti, glavni stručni suradnik u Direkciji za istraživanja Hrvatske narodne banke, Zagreb. Članak primljen u uredništvo: 02. 09. 2000.

¹ Autori zahvaljuju dr. Alenu Belullu za veoma korisne primjedbe na prvu verziju rada. Te su primjedbe dovele do zajedničkog rada koji će, nadamo se uskoro biti objavljen. Odgovornost za stavove i rezultate u ovome radu pripada isključivo autorima.

Danas su ta pitanja u samom središtu makroekonomskih istraživanja i rasprava diljem svijeta. No nema naznaka o mogućnosti skorog konsenzusa. Barry Eichengreen (1996.) vidi konsenzus u tome da su fluktuirajući tečajevi tu da ostanu, a Guillermo Calvo (1999.) ambiciozno govori o ponovnom slaganju mozaika na prijelazu tisućljeća, naravno, u korist fiksnih tečajeva i monetarnih unija. Robert Mundell (1999.) nastavlja se zalagati za vezanje tečajeva zemalja bliskih Europi uz euro, no Paul Masson (1999.) i Frederick Mishkin (1999.a, 1999b.) upozoravaju na izloženost spekulativnim napadima i na druge slabosti sustava fiksnih tečajeva. Zalažu se za fleksibilnije tečajne režime poput izravnog ciljanja niske inflacije.

Dvojbe ostaju, premda oštro zagrijavanje rasprave u proteklim mjesecima budi nadu da bi se uskoro ipak mogla povećati količina znanja o izboru optimalnih tečajnih režima. Mi u ovome radu nemamo ambiciju pridružiti se toj raspravi, nego želimo ispitati postoji li povezanost između poslovnih ciklusa država u Srednjoj Europi.

Istraživanja usklađenosti cikličkih kretanja nezaposlenosti što su ih proveli Laurence Boone i Mathilde Maurel (1998., 1999.) u sklopu londonskog Centra za istraživanja ekonomske politike (CEPR) bila su prva istraživanja te vrste koja su obuhvatila i neke tranzicijske zemlje Srednje Europe. Rezultati su pokazali visok stupanj usklađenosti cikličkih kretanja nezaposlenosti u Njemačkoj i u četiri tranzicijske zemlje koje su kandidati prvoga kruga za ulazak u EU. Dio promjene nezaposlenosti koji je objašnjen njemačkim cikličkim promjenama nezaposlenosti bio je najveći u Mađarskoj (86%). Slijedila je Slovačka sa 83% i Češka sa 63%. Najmanji dio promjene objašnjen je u Poljskoj (55%), ali se i ta korelacija može smatrati čvrstom.

U spomenutom je istraživanju posebno zanimljivo to što je stupanj povezanosti četiriju tranzicijskih zemalja s Njemačkom bio jači od povezanosti između Njemačke, Španjolske i Italije i manji od stupnja međusobne povezanosti Njemačke i Francuske. Njemački šokovi nezaposlenosti objasnili su 43% španjolske i 18% talijanske varijacije cikličke nezaposlenosti i čak 91% francuske varijacije cikličke nezaposlenosti. Unatoč velikim razlikama u snazi veza i stupnju gospodarske razvijenosti,² sve su se spomenute zemlje odlučile za euro, premda su sa stajališta koordinacije ciklusa za to imale mnogo manje razloga nego što ih danas imaju napredne tranzicijske zemlje.

Glavna razlika između Francuske, s jedne, i Španjolske i Italije sa druge strane, jest u tome što su druge dvije zemlje izlaskom iz ERM-a i dopuštanjem deprecijacije tečaja 1992./93. izvele prilagodbu tečaja koja se nije razvila u inflaciju i u rast kamatnih stopa. Inflacija je ostala niska, a kamatne su stope zabilježile pad. Suprotno tome, Francuska tada nije izvela prilagodbu tečaja. Počevši od 1987., čvrsto je vezala franak uz DEM, kako bi izbjegla štetne posljedice visoke inflacije koju je iskusila u tijeku osamdesetih. Podaci u tablici 1. pokazuju da Francuska zbog toga

² Španjolski je BDP po stanovniku u trenutku pristupanja euro-zoni bio oko dva puta manji od njemačkoga.

nije platila cijenu u usporedbi sa drugim zemljama. Naprotiv, Francuska je zabilježila brz rast nakon europskih valutnih kriza na početku devedesetih. Usporedba Francuske sa Španjolskom i Italijom (zemljama koje su dopustile znatno slabljenje valuta) ne otkriva pretpostavljenu prednost od puštanja tečaja i prijelaza na slobodniji režim domaće monetarne politike u Španjolskoj i Italiji. Naprotiv, sve su promatrane zemlje u devedesetim godinama prošle kroz razdoblje rasta nezaposlenosti.

Podaci u tablici 1. također pokazuju da je 1993. bila kritična godina u kojoj su sve promatrane zemlje zabilježile približno jednak pad realnoga BDP-a (-1,2% u Španjolskoj i Italiji, -1,3% u Francuskoj). U toj je godini i Njemačka, pod teretom ujedinjenja, zabilježila pad BDP-a jednakog intenziteta (-1,2%). Imajući na umu neosjetljivost godišnjih podataka o realnom BDP-u i nezaposlenosti u Španjolskoj, Francuskoj, Italiji i Njemačkoj na njihove različite tečajne politike, postavlja se pitanje nije li i u tako velikim gospodarskim sustavima učinak međunarodnog prenošenja kriznih impulsa (čije je podrijetlo u tom primjeru bilo u Njemačkoj) mnogo jači od poništavajućih (protucikličkih) učinaka nacionalnih monetarnih i tečajnih politika. Slijedi i pitanje: ako su čimbenici međunarodnoga prelijevanja poslovnih ciklusa tako važni i prevladavajući nad nacionalnim monetarnim politikama u velikim gospodarskim sustavima, nemaju li oni još i važniju ulogu u malim i otvorenim gospodarskim sustavima tranzicijske Srednje Europe? To ćemo pitanje istražiti u ovome radu i pokazat ćemo da je odgovor na njega pozitivan. Štoviše, pokazat ćemo da je hrvatsko gospodarstvo izrazito osjetljivo na egzogene makrekonomske šokove koji potječu iz Njemačke.

Tablica 1.

TEČAJ, REALNI OUTPUT I NEZAPOSLENOST U ŠPANJOLSKOJ,
U ITALIJI I FRANCUSKOJ
1991. - 1998.

Godina	Španjolska			Italija			Francuska		
	E*	y**	U%	E*	y**	U%	E*	y**	U%
1991.	103,9	2,3	16,3	1241	1,1	10,9	5,64	0,8	9,4
1992.	102,5	0,7	18,4	1235	0,6	10,7	5,30	1,2	10,3
1993.	127,5	-1,2	22,7	1578	-1,2	10,2	5,66	-1,3	11,6
1994.	134,0	2,1	24,2	1612	2,2	11,3	5,55	2,8	12,3
1995.	124,7	2,9	22,9	1629	2,9	12,0	4,99	2,1	11,7
1996.	126,7	2,4	22,2	1543	0,9	12,1	5,12	1,6	12,4
1997.	146,5	3,5	20,8	1704	1,5	12,3	5,84	2,3	12,5
1998.	149,0	3,8	18,8	1731	1,4	12,3	5,88	3,1	11,6

* Prosječan godišnji nominalni tečaj nacionalne valute prema USD.

** Godišnja stopa rasta realnoga BDP-a.

Izvor: "World Economic Outlook", May 1999., IMF: Washington.

Uvodna usporedba Francuske, Italije i Španjolske upućuje na to da snaga veza između realnih šokova možda nije egzogena pojava. Usklađenost realnih kretanja možda se jednim dijelom može tumačiti kao posljedica izbora politike tečaja. Ta hipoteza proizlazi iz činjenice da je franak u tijeku devedesetih ostao usko vezan uz DEM, a lira i peseta izašle su iz ERM-a na početku devedesetih. Zbog toga je korelacija fluktuacija nezaposlenosti između Njemačke i Francuske mogla biti mnogo uža nego između Njemačke i Španjolske i Italije. No to nas ne smije navesti na olako zaključivanje o tome da je izbor politike tečaja glavna ili jedina odrednica koordinacije ciklusa. Na nju mogu utjecati i povijesne okolnosti, tj. smjerovi razmjene dobara i faktora proizvodnje.

Iz toga se mogu izvući tri važne pouke. Prvo, stupanj koordinacije poslovnih ciklusa nije najvažniji pokazatelj za odluku o ulasku ili neulasku u monetarnu uniju ili neki međunarodni ugovor o politici tečaja. Funkcioniranje ekonomije unutar monetarnog odnosno tečajnog ugovora, ili čak samo njihova bliskost i povezanost u razmjeni, može dovesti do cikličke koordinacije gospodarske aktivnosti (Frankel i Rose, 1998.).

Drugo, a to je zaključak što ga naglašavaju Boone i Maurel (1998., 1999.), stupanj cikličke koordinacije također može biti posljedica povijesnih veza, kao što može biti i posljedica činjenice da su sve promatrane zemlje u kojima je ustanovljen visok stupanj cikličke koordinacije (Francuska, srednjoeuropske tranzicijske zemlje) na ovaj ili onaj način vezale svoje valute uz DEM, što je bila posljedica njihove borbe protiv inflacije (Begg, 1996.; Bufman i Leiderman, 1999.). Ta je činjenica također mogla biti i posljedica povijesnih veza i strukture razmjene dobara i faktora proizvodnje. Utoliko i institucionalni i zemljopisni čimbenici mogu odrediti optimalni tečajni režim i stupanj cikličke koordinacije, no u tim je pitanjima veoma teško otkriti uzročno-posljedične odnose.

Treće, zbog veličine nacionalne ekonomije, strukture međunarodne razmjene u kojoj sa 60% sudjeluje EU i zbog politike implicitnog vezanja tečaja kune za DEM, moguće je očekivati veoma visok stupanj korelacije ciklusa između Hrvatske i Njemačke, ali i između Hrvatske i drugih srednjoeuropskih tranzicijskih zemalja, u čemu bi morala posredovati njihova povezanost s Njemačkom. Te se veze ispituju u ovome radu. No još je jedanput potrebno upozoriti na to da metoda koja se rabi u takvim istraživanjima ne omogućuje izravno otkrivanje uzroka cikličke koordinacije.

Najveći problem pri takvim istraživanjima jest kako izolirati cikličke od strukturnih, odnosno fundamentalnih komponenti kretanja makroekonomskih veličina. Njihovo je razlikovanje važno zbog toga što iskustvo upozorava na to da se monetarnom politikom može učinkovito djelovati samo na cikličku komponentu gospodarskih kretanja.³ Uzrok mogu biti bitno drukčiji uzroci strukturnih i cikličkih

³ Naravno, uz pretpostavku da čitatelj prihvaća stajalište kako monetarna politika može imati realne učinke u kratkome roku. Za čitatelja koji vjeruje u apsolutnu neutralnost monetarne politike njezino je spominjanje u ovom kontekstu izlišno.

kretanja. Prva vrsta kretanja može se, na primjer, odvijati pod dominantnim utjecajem institucionalne organizacije tržišta rada. Isti zajednički šok koji u dvije zemlje podjednako poveća potražnju, u jednoj se zemlji, gdje su sindikati slabi, može dijelom preliti u rast zaposlenosti (a jedinični će troškovi rada rasti sporije), a u drugoj će se zemlji, s jakim sindikatima, taj šok sasvim amortizirati rastom plaća. U toj zemlji neće porasti zaposlenost. Zbog toga analitičar najprije mora u podacima otkriti fundamentalne strukturne trendove. Oni odražavaju pojave koje nisu cikličke i na koje monetarna politika najvjerojatnije ne može utjecati. Potom mora pretpostaviti da preostali dio ponašanja pojave, iz koje je sada isključen trend, sadrži cikličku komponentu koja se analizira.

U narednom se odjeljku prikazuju rezultati koji su dobijeni nakon detrendiranja Hodrick-Presottovim filtrom, tj. istom metodom kakvu su primijenili Boone i Maurel (1999.), što naše rezultate čini usporedivima. Rezultati pokazuju da postoji uska ciklička povezanost između naprednih tranzicijskih zemalja i Njemačke (čime se potvrđuju prvi rezultati Boonea i Maurel). Također se pokazuje da u Hrvatskoj, Češkoj i Mađarskoj postoji veoma sličan vremenski obrazac reakcije nezaposlenosti na makroekonomski šok, epicentar kojeg je u Njemačkoj ako se promatra prvih 24 i 12 mjeseci nakon pojave šoka, ali to ne vrijedi za prijenos šoka od 36 mjeseci .

U ovome radu pokazujemo da Srednja Europa čini optimalno valutno područje u Mundellovu smislu (1961.), ali i upozoravamo da se odluka o valutnom režimu ne smije donositi samo na osnovi kriterija cikličke koordinacije. Za to postoje dva razloga. Prvo, koordinacija ciklusa može biti endogena, tj. može nastati kao proizvod prethodne odluke o nekoj vrsti vezanja tečaja s tečajem valute većeg monetarnoga područja (države ili unije). Drugo, koordiniranost ciklusa može biti proizvod dubljih strukturnih i/ili povijesnih veza. Drugi je razlog dodatni argument u prilog stupanju u monetarnu uniju ili neki sličan valutni aranžman. Prvi bi razlog bio argument protiv unije, ako bi se uspjelo dokazati da veća fleksibilnost tečaja i slobodnija monetarna politika mogu ublažiti utjecaj domaćih i uvezenih cikličkih fluktuacija. Takvo je nešto, međutim, veoma teško dokazati. To dokazivanje izlazi iz teme ovoga rada u kojem se rabi metoda koja ne omogućuje analizu uzroka i dosega cikličke koordinacije. Cilj nam je skroman: pokazati postojanje uske povezanosti poslovnih ciklusa u Srednjoj Europi.

Rezultati empirijske analize

U ovom ćemo se odjeljku koristiti metodološkim pristupom Boonea i Maurel (1999.). Jedan od glavnih zaključaka njihova istraživanja jest to da će koristi od pripajanja tranzicijskih zemalja EU-a i, eventualno, EMU-a biti veće od troškova zbog sličnosti njihovih poslovnih ciklusa. Pretpostavka njihove analize jest da monetarna politika primarno djeluje u smjeru izgladivanja fluktuacija poslovnog ciklusa, pa su stoga vremenske serije dekomponirane na trend i cikličku komponentu. Ciklička je komponenta po pretpostavci povezana sa šokovima potražnje za koje se pretpostavlja da nemaju dugoročan utjecaj na output i nezaposlenost. Mi smo u

ovom istraživanju prihvatili i metodu i pretpostavke, pa se jedina novost koju donosi ovo istraživanje odnosi na uključivanje Hrvatske i dviju naprednijih tranzicijskih zemalja reakcije kojih se istražuju. Tako su odabrane Češka i Mađarska. Dodatna je razlika u rezultatima moguća zbog toga što su Boone i Maurel rabili vremenske serije nezaposlenosti koje počinju 1990., a završavaju u godini 1997., a naše serije počinju sa siječnjem 1992., a završavaju kolovozom godine 1999.

Na slikama u Prilogu 1. predočene su stope nezaposlenosti u izvornom obliku. Uočljivo je da stopa nezaposlenosti u svim zemljama ima izrazitu trend-komponentu. Izvorni su podaci desezonirani, a onda je na njih primijenjen Hodrick-Prescottov filtar (Prilog 5.) radi izdvajanja trenda. U Prilogu 2. zamjetni su bitno različiti trendovi nezaposlenosti dobijeni Hodrick-Prescottovim (HP) filtrom u promatranim državama. Hrvatska i Češka su nakon pada trend-nezaposlenosti do godine 1995., odnosno 1996., počele bilježiti rast nezaposlenosti. Njemačka je bilježila rast trend-nezaposlenosti do svršetka 1997., odnosno do početka 1998., nakon čega započinje njezin pad, a Mađarska je nakon dvogodišnjeg rasta trend-nezaposlenosti u ostalom razdoblju bilježila pad. U ovom se radu ne bavimo uzrocima prikazanih razlika u kretanju trend-nezaposlenosti. Prikazani trendovi upućuju na potrebu detrendiranja podataka o nezaposlenosti, da bi se izolirala ciklička komponenta i na njoj provela analiza. Od vrijednosti originalne serije oduzeta je vrijednost trenda prema Hodrick-Prescottu, pa je tako dobijena ciklička komponenta. Ciklička komponenta četiriju serija prikazana je na slikama u prilogu 3. Podsjetimo, ciklička komponenta nezaposlenosti u promatranim zemljama aproksimirat će njihov poslovni ciklus. U nastavku istražujemo kako poslovni ciklus u trima zemljama reagira na šok u njemačkom poslovnom ciklusu i postoji li sličnost između tih reakcija.

Prije poduzimanja tih dvaju koraka analize, valjalo je modelirati proces koji je generirao njemačku cikličku komponentu nezaposlenosti. Bilo ga je potrebno identificirati i okarakterizirati. Za to je primijenjen pristup ARMA(p,q) modeliranja. Uz dva osnovna alata identifikacije procesa, funkciju autokorelacije i parcijalne autokorelacije, odabran je AR(1) model. Dakle, ciklička komponenta njemačke nezaposlenosti opisana je modelom:

$$(U)_{G,t} = \alpha_G (U)_{G,t-1} + \varepsilon_{G,t}, \quad (1)$$

gdje U predočuje cikličku nezaposlenost, supskript G govori da je riječ o Njemačkoj, a reziduali $\varepsilon_{G,t}$ označuju njemački šok koji uzrokuje cikličko kretanje njemačke nezaposlenosti (Prilog 4). Ta je serija reziduala poslužila za regresije koje će biti izračunane u prvom koraku analize. Iz Priloga 4. vidljiva su dva pozitivna šoka, jači u svibnju 1994. i slabiji u siječnju 1997. i negativan šok u svibnju godine 1995.

U prvom su koraku analize fluktuacije poslovnog ciklusa (ciklička komponenta nezaposlenosti) u svakoj od promatranih zemalja regresirane na zajednički njemački šok (reziduali iz jednadžbe (1)) koji je pomaknut u vremenu, pri čemu broj pomaka iznosi 36, 24 i 12 ili, simbolički:

$$U_{Z,t} = \sum_{k=0}^p \beta_{Z,k} \varepsilon_{G,t-k} + u_{Z,t}, \quad (2)$$

gdje su Z Hrvatska, Češka i Mađarska, a $p = 36, 24, 12$. Iz tih regresija vidjet ćemo koliki se dio fluktuacija nezaposlenosti promatranih triju zemalja može objasniti njemačkim šokom. Koeficijent determinacije regresija prikazanih jednadžbom (2) pokazat će udio varijance poslovnog ciklusa analiziranih zemalja koju možemo objasniti njemačkim šokom. Primijenjeni su pomaci $p = 36, 24, 12$ kako bismo otkrili jesu li parametri robusni ili otporni na promjenu pomaka. Vektor parametara $\beta_{Z,k}$ uzet je kao funkcija odgovora poslovnih ciklusa promatranih zemalja na njemački šok.

U tablici 2. dani su koeficijenti determinacije iz jednadžbe (2) sa 36, 24 i 12 pomaka za njemački šok. Visoka vrijednost koeficijenta determinacije pokazuje da je trošak formiranja monetarne unije manji. Kao što vidimo, za sve tri zemlje moguće je objasniti velik postotak varijance njihovih poslovnih ciklusa, tj. postoji jaka linearna veza između njemačkog šoka u nezaposlenosti s ciklusima u nezaposlenosti promatranih zemalja za sve pomake. Pritom se uočava sličnost s rezultatima koje su dobili Boone i Maurel (1999.). Slijedimo li njihov kriterij, znači da stupanj autonomije monetarne politike tih zemalja u odnosu prema Njemačkoj mora biti mali. Uočavamo također da osjetljivost na odabrani broj pomaka nije velika.

Tablica 2.

KOEFICIJENTI DETERMINACIJE JEDNADŽBE (2)

	36 pomaka	24 pomaka	12 pomaka
Hrvatska	0,97	0,90	0,79
Češka	0,97	0,95	0,94
Mađarska	0,88	0,82	0,83

U drugom koraku analize istraživana je sličnost odgovora nezaposlenosti tranzicijskih zemalja na zajednički šok ispitivanjem koreliranosti vektora koeficijenata iz regresije (2). Uz visoku linearnu povezanost iz prethodnog koraka morala bi postojati sličnost reakcijskih odgovora promatranih zemalja (pozitivne i visoke korelacije) da bi monetarna unija bila opravdana. Povezanost vektora koeficijenata može upućivati na pozitivnu i/ili negativnu i slabu i/ili jaku korelaciju. Ako su korelacije pozitivne i veće, dvije su zemlje sličnije u terminima relativnih odgovora na zajednički šok. Potrebno je testirati koeficijente korelacije $r(\beta_{Z,k}, \beta_{Zl,k})$ za $Z \neq Zl$. Ti su koeficijenti prikazani u tablicama 3., 4. i 5.

Tablica 3.

KORELACIJA IZMEĐU VEKTORA REAKCIJSKIH ODGOVORA
DVIJU ZEMALJA NA NJEMAČKI ŠOK (36 POMAKA)

	Hrvatska	Češka	Mađarska
Hrvatska	1,00		
Češka	-0,03	1,00	
Mađarska	0,47	-0,62	1,00

Rezultati prikazani u tablici 3. ne upućuju na to da promatrane tri zemlje tvore homogenu grupu zemalja. Korelacija njihovih odgovora nije istog predznaka, što znači da one ne reagiraju na isti način na zajednički šok. Češka ne reagira u istom smjeru kao Hrvatska i Mađarska, ali postoji prilično velika sličnost u reakciji između Mađarske i Hrvatske. Negativna korelacija među zemljama može biti rezultat od različitog vremena prijenosa šoka ili asimetričnih kretanja outputa.

Tablica 4.

KORELACIJA IZMEĐU VEKTORA REAKCIJSKIH ODGOVORA
DVIJU ZEMALJA NA NJEMAČKI ŠOK (24 POMAKA)

	Hrvatska	Češka	Mađarska
Hrvatska	1,00		
Češka	0,14	1,00	
Mađarska	0,75	0,04	1,00

U ovom slučaju tri tranzicijske zemlje tvore homogenu skupinu zemalja (njihovi su odgovori pozitivno korelirani), tj. slično reagiraju na njemački šok. Pritom se ispunjava kriterij poželjnosti pozitivne koreliranosti funkcija reakcijskih odgovora. Uočava se velika sličnost u reakciji između Hrvatske i Mađarske. Rezultati u tablici 4. bliži su zaključcima Boonea i Maurel (1999.).

Tablica 5.

KORELACIJA IZMEĐU VEKTORA REAKCIJSKIH ODGOVORA
DVIJU ZEMALJA NA NJEMAČKI ŠOK (12 POMAKA)

	Hrvatska	Češka	Mađarska
Hrvatska	1,00		
Češka	0,73	1,00	
Mađarska	0,28	0,21	1,00

Korelacija vektora dobijenih za 12 pomaka pokazuje homogenost i najveću sličnost reakcijskih odgovora promatranih triju zemalja.

Rezultati korelacije iz posljednjih dviju tablica upućuju na to da promatrane tranzicijske zemlje i Njemačka čine optimalno valutno područje u Mundellovu (1961.) smislu. Taj zaključak valja prihvatiti s oprezom, jer ciklička koordiniranost može biti posljedica vezanja tečajeva uz DEM. Korelacija vektora reakcijskih odgovora na njemački šok uz 36 pomaka nije pokazala da tri promatrane zemlje čine homogenu grupu zemalja.

Zaključak

Najvažnijim doprinosom ove analize držimo to da je stupanj cikličke koordinacije između Njemačke i Hrvatske veoma visok. Usto, veoma je veliki postotak fluktuacija poslovnog ciklusa promatranih tranzicijskih zemalja objašnjen njemačkim šokom. Dalje, reakcijski odgovori na zajednički šok pozitivno su korelirani za 24 i 12 pomaka, čime su uglavnom potvrđeni nalazi Boonea i Maurel (1999.) o sličnosti u reagiranju promatranih zemalja na zajednički šok. Drugim riječima, u roku od dvije i jedne godine sve tri promatrane zemlje slično reagiraju, pa tvore homogenu skupinu zemalja. Za 36 mjeseci vremenskog pomaka prijenosa zajedničkog šoka ne postoji pozitivna koreliranost funkcija reakcijskih odgovora.

Svjesni smo činjenice da mjera sličnosti možda odražava činjenicu da su promatrane zemlje već na neki način vezale svoje valute uz DEM. Zapravo, fluktuacije poslovnih ciklusa sličnije su ako su valute vezane zato što već postoji zajednička monetarna politika. Uzroci koreliranosti makroekonomskih šokova mogu, dakle, biti odraz tečajnih režima koji zbog vezanja valuta uz DEM čine sklad ciklusa endogenim (omogućuju uvoz njemačkoga ciklusa). No, uzroci mogu biti mnogo dublje, strukturne naravi: povijesne veze, transferi, struktura razmjene roba, usluga i faktora proizvodnje - sve to utječe na cikličku povezanost. Na osnovi te analize nije moguće razlučivati uzroke ni zaključivati o njihovoj povezanosti. Zbog toga ta analitička metoda ne omogućuje donošenje čvršćih zaključaka o optimalnosti

nekoj valutnoga područja, premda se može govoriti o naznakama koje valja dalje istražiti. Ponovimo, jedan od zaključaka Boonea i Maurel (1999.) bio je da je korist od pridruživanja EU ili EMU visoka za srednjoeuropske zemlje, polazeći sa stajališta sličnosti njihovih ekonomskih ciklusa. Prema tim autorima tranzicijski bi proces i realna konvergencija bili ubrzani stabilnim tečajnim režimom. Troškovi vezanja valuta tranzicijskih zemalja odnose se na stupanj asimetričnosti ekonomskih ciklusa, za koji je dokazano da je mali. Prema tome, i troškovi vezanja valuta bili bi mali. Ti autori čvrsto stoje na stajalištu da bi korist od vezanja valuta bila veća od troškova.

Kratkoća vremenskih serija i niska kakvoća podataka o nezaposlenosti u svakom slučaju ograničuju zaključivanje. Mogućnost lažne detekcije cikličnosti uporabom Hodrick-Prescottova filtra također se ne može zanemariti. Stoga ovdje govorimo o pet mogućih smjerova u kojima bi dalje istraživanje, ako njima krene, moglo pridonijeti povećanju znanja. Prvo, potrebno je poboljšati kakvoću mjerenja nezaposlenosti. Drugo, potrebno je istražiti koliko su ti rezultati osjetljivi na tehnike filtriranja podataka. Potrebno je ulagati dalje analitičke napore u razdvajanje cikličke komponente i trend komponente i u objašnjenje kretanja trend-komponente i istraživanje uzroka njezina kretanja. Treće, potrebno je proširiti istraživanja na druge makroekonomske serije. Na primjer, premda se problem kakvoće podataka podjednako odnosi na statistiku industrijske proizvodnje, već sada može započeti istraživanje cikličke korelacije na tim podacima. Četvrto, potrebno je proširivati skup zemalja u istraživanju. Zemlje Srednjoeuropske inicijative (SEI) čine se zanimljivim uzorkom za istraživanje sličnosti reakcijskih funkcija. SEI uključuje Austriju i Italiju, sve napredne tranzicijske zemlje (osim baltičkih država), ali i zemlje koje zaostaju u procesu tranzicije (Bugarska, BiH, Albanija, Rumunjska). SEI obuhvaća i tri zemlje članice eurozone, pa bi uzorak EU-11 i SEI svakako bio najzanimljiviji za dalja istraživanja. Peto, kada je riječ o istraživanjima za Hrvatsku, s agregatnih se podataka možemo spustiti na niže razine agregacije (pojedine grane) da bismo utvrdili gdje je najveća osjetljivost na vanjske makroekonomske šokove i je li ta osjetljivost očekivana i pojavljuju li se u granama i proizvodi koji najviše sudjeluju u međunarodnoj razmjeni.

LITERATURA

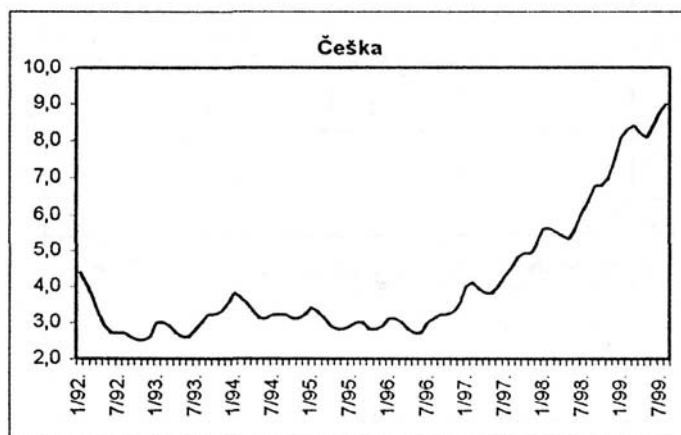

1. *Asea, P. K. & Mendoza, E. G.*: "Do Long-Run Productivity Differentials Explain Long-Run Real Exchange Rates", IMF, Working Paper, No. 60, 1994.
2. *Baxter, M. & King, R. G.*: "Measuring Business-Cycles: Approximate Band-Pass Filters for Economic Time Series, National Bureau of Economic Research, Working Paper, No. 5022, 1995.
3. *Begg, D.*: "Monetary Policy after Half a Decade of Transition", IMF, Working Paper, No. 108, 1996.
4. *Beveridge, S. & Nelson, C. R.*: "A New Approach to the Decomposition of Economic Time Series into Permanent and Transitory Components with Particular Attention to Measurement of the Business Cycle", *Journal of Monetary Economics*, 7, 1981., str. 151-174.



5. *Blanchard, O. J. & Quah, D.*: "The Dynamic Effect of Aggregate Demand and *Supply Disturbances*," *American Economic Review*, 79, 1989., str. 655-673.
6. *Boone, L. & Maurel, M.*: "Economic Convergence of the CEECS with the EU", CEPR, Discussion Paper, No. 2018, 1998.
7. *Boone, L. & Maurel, M.*: "An Optimal Currency Area Perspective of the EU Enlargement to the CEECS", CEPR, Discussion Paper, No. 2119, 1999.
8. *Bufman, G. & Leiderman, L.*: "Monetary Policy Strategies for Disinflation: Lessons from Recent Experiences in Transition Economies and Israel", u Blejer, M. I. and Škreb, M. (ur.): "Central Banking, Monetary Policies, and the Implications for Transition Economies", Amsterdam, Kluwer Academic Publishers, 1999., str. 215-269.
9. *Calvo, G.*: "Fixed versus Flexible Exchange Rates: Preliminaries of a Turn-of-Millennium Rematch" <http://www.bsos.umd.edu/econ/ciecalvo.htm>.
10. *Cochrane, J. H.*: "Permanent and Transitory Components of GNP and Stock Prices, *Quarterly Journal of Economics*", 61, 1994., str. 241-265.
11. *de Brouwer, G.*: "Estimating Output Gaps", Reserve Bank of Australia Research, Discussion Paper, No. 9809, 1998.
12. *Eichengreen, B.*: "Globalizing Capital: A History of the International Monetary System", Princeton, Princeton University Press, 1996.
13. *Frankel, J. A. & Rose, A. K.*: "The Endogeneity of Optimum Currency Area Criteria", *The Economic Journal*, 108, 1998., str. 1009-1025.
14. *Guay, A. & St-Amant, P.*: "Do the Hodrick-Prescott and Baxter-King Filters Provide a Good Approximation of Business Cycles", Center for Research on Economic Fluctuations and Employment, Université du Québec à Montréal, Working Paper, No. 53, 1997.
15. *Harvey, A. C. & Jaeger, A.*: "Detrending, Stylized Facts and the Business Cycle", *Journal of Applied Econometrics*, Vol. 8, 1991., str. 231-247.
16. *Harvey, A. C.*: "Forecasting, Structural Time Series Models and the Kalman Filter", Cambridge University Press, 1989.
17. *Hausmann, R. et. al.*: "Financial Turmoil and the Choice of the Exchange Rate Regime", Inter American Development Bank, Working Paper, 1999.
18. *Hodrick, R. J. & Prescott, E. C.*: "Post-War U.S. Business Cycles: An Empirical Investigation", Discussion Paper, Carnegie-Mellon University, No. 451, 1980.
19. *King, R. G. & Rebelo, S. T.*: "Low Frequency Filtering and Real Business Cycles", *Journal of Economic Dynamics and Control*, 17, 1993., str. 207-231.
20. *Kydland, F. E. & Prescott, E. C.*: "Business Cycles: Real Facts and a Monetary Myth", Federal Reserve Bank of Minneapolis Quarterly Review, 14, Spring 1990., No. 3-18.
21. *Laxton, D. & Tetlow, R.*: "A Simple Multivariate Filter for the Measurement of Potential Output", Bank of Canada Technical Report, No. 59, 1992.
22. *Lucas, R. E.*: "Methods and Problems in Business Cycle Theory", *Journal of Money, Credit and Banking*, 12, 1980., str. 696-715.
23. Main Economic Indicators, OECD, Different Issues.

24. *Masson, P. A.*: "Monetary and Exchange Rate Policy of Transition Economies of Central and Eastern Europe After the Launch of EMU", u Blejer, M. I. i Škreb, M. (ur.): "Central Banking, Monetary Policy and the Implications for Transition Economies", London, Kluwer Academic Publishers, 1999., str. 429-452.
25. *Mishkin, F.*: "International Experiences with Different Monetary Policy Regimes", NBER, Working Paper, Series 6965, i u Special Issue: Monetary Policy Rules. A Conference Organized by Sveriges Riksbank (Bank of Sweden) and the Institute for International Economic Studies, Stockholm University, 1999.
26. *Mishkin, F.*: Lessons from the Asian Crises, NBER, Working Paper, Series 7102, 1999.
27. *Mundell, R. A.*: "A Theory of Optimum Currency Areas", *American Economic Review*, 51, 1961., str. 657-665.
28. *Mundell, R. A.*: "The International Impact of the Euro and its Implications for Transition Countries", u Blejer, M. I. i Škreb, M. (ur.): "Central Banking, Monetary Policy and the Implications for Transition Economies". London, Kluwer Academic Publishers, 1999., str. 403-428.
29. *Reeves, J. J., Blyth, C. A., Triggs, C. M. & Small, J. P.*: "The Hodrick-Prescott Filter, a Generalisation, and a New Procedure for Extracting an Empirical Cycle from a Series", Auckland, The University of Auckland, Department of Economics, Working Paper, No. 160, 1996.
30. *The Vienna Institute Monthly Report*, The Vienna Institute for Comparative Economic Studies, Different Issues.
31. *Watson, M. W.*: "Univariate Detrending Methods with Stochastic Trends", *Journal of Monetary Economics*, 18, 1986., str. 49-75.

Prilog 1.

STOPE NEZAPOSLENOSTI
U postocima, izvorni podaci







Izvor: The Vienna Institute Monthly Report.



The Vienna Institute for Comparative Economic Studies, Različiti brojevi.

Main Economic Indicators, OECD, Različiti brojevi.

Prilog 2.



HODRICK-PRESCOTT TREND DESEZONIRANE
STOPE NEZAPOSLENOSTI
U postocima







Prilog 3.


CIKLIČKA KOMPONENTA NEZAPOSLENOSTI
U postocima





Prilog 4.

NJEMAČKI ŠOK (REZIDUAL AR (1))
MODELA CIKLIČKE NEZAPOSLENOSTI



Prilog 5.

HODRICK-PRESCOTTOV FILTAR

Postoji duga tradicija u težnji ekonomista za razdvajanjem stalne od kratkotrajne komponente unutar vremenske serije. Ti su naponi bili osobito veliki kad je riječ o školi realnoga poslovnog ciklusa (RBC). Najpopularnija metoda zasnovana na filtru jest ona koju su preporučili Hodrick i Prescott (1980.). Oni su pošli od Lucasove (1981.) teorije, prema kojoj agregatne ekonomske varijable ponavljaju fluktuacije oko dugoročnog trenda. U spomenutom radu istraživali su poslovne cikluse u Sjedinjenim Državama nakon Drugoga svjetskog rata. Empirijski dio i teza Hodrickova i Prescottova rada (1980.) nisu predmet ovoga priloga, osim u dijelu koji se odnosi na izračunavanje komponente rasta opažene vremenske serije. Hodrickov i Prescottov statistički pristup nije bio pristup standardne analize vremenskih serija jer njihovo prethodno znanje o procesu generiranja vremenske serije, nije bilo osobito raznoliko, pa nisu mogli specificirati model vjerojatnosti kakav bi bio potreban za primjenu takve analize. Oni su više pozornosti pridali ekonomskoj teoriji. Osnovna hipoteza, koja se zasnivala na teoriji rasta, jest da komponenta rasta agregatnih ekonomskih vremenskih serija varira izglađeno u vremenu.

Hodrick i Prescott polaze sa stajališta da je opažena vremenska serija zbroj cikličke komponente i komponente rasta. Pretpostavili su također i sezonsku komponentu koja se prethodno uklanja. Izračunavanje cikličke komponente jednostavno je računanje razlike između opaženih vrijednosti i ocijenjene komponente rasta. Hodrick-Prescott (HP) filtrom naziva se algoritmom izračunavanja komponente rasta. Filtar je postao popularan u primijenjenoj makroekonomiji u posljednjih petnaest godina. Konceptualno, Hodrick i Prescott pošli su od ovoga: vremenska serija y_t zbroj je komponente rasta g_t i cikličke komponente c_t , simbolički:

$$y_t = g_t + c_t, \quad \text{za } t = 1, \dots, T.$$

Mjera izglađenosti komponente rasta $\{g_t\}$ zbroj je kvadrata njegovih drugih diferencija, a c_t devijacije su od g_t , pa se pretpostavlja da je njihov prosjek u dugom razdoblju približno jednak nuli. Problem određivanja komponente rasta jest:

$$\text{Min}_{\{g_t\}_{t=-1}^T} \left\{ \sum_{t=1}^T c_t^2 + \lambda \sum_{t=1}^T \left[(g_t - g_{t-1}) - (g_{t-1} - g_{t-2}) \right]^2 \right\},$$

gdje je $c_t = y_t - g_t$. Parametar λ pozitivan je broj koji "kažnjava" varijabilnost komponente rasta. Što je parametar λ veći, rezultirajuća je serija izglađenija. Za iznimno veliki λ , u optimumu sve komponente $g_{t+1} - g_t$ moraju biti blizu konstanti β i stoga g_t arbitrarno blizu $g_0 + \beta t$. To znači da je granica rješenja problema minimizacije, kada λ teži beskonačnosti, model linearnog trenda uz upotrebu najmanjih kvadrata.

Podaci što su ih analizirali Hodrick i Prescott u radu (1980.) transformirani su u logaritamski oblik, tako da promjena komponente rasta, $g_t - g_{t-1}$, odgovara stopi rasta.

Ako su ciklička komponenta i druge diferencije komponente rasta jednako i neovisno distribuirane normalne varijable sa sredinama jednakima nuli i varijancama σ_1^2 i σ_2^2 (što obično nisu), uvjetno očekivanje od g_t , uz dana opažanja, biti će rješenje problema minimizacije kada je $\sqrt{\lambda} = \sigma_1 / \sigma_2$.

Kalmanova tehnika izgladivanja primijenjena je da bi se izračunala uvjetna očekivanja od g_t uz dato y_t . Prema Hodricku i Prescottu (1980.), pet je postotaka cikličke komponente otprilike jednako osmini postotne promjene stope rasta u jednom tromjesečju. Stoga su kao vrijednost parametra izgladivanja izabrali $\sqrt{\lambda} = 5/(1/8) = 40$ ili $\lambda = 1600$, ali je upitna osjetljivost rezultata na izabrani parametar λ . HP1600 filtar gotovo je standardni način povlačenja izgladene linije trenda kroz cikličku seriju.

Drugi član navedenog zbroja, $((g_{t+1} - g_t) - (g_t - g_{t-1}))$, ili $\Delta^2 g_t$, aproksimacija je druge derivacije od g u vremenu t . Postoje dvije suprotnosti u problemu Hodrick-Prescottove minimizacije. S jedne strane pokušava se minimizirati zbroj kvadrata cikličkih reziduala, a sa druge strane, želi se minimizirati sumu kvadrata $\Delta^2 g_t$. Parametar izgladivanja λ daje relativni ponder tim dvjema suprotnostima. Vrijednost parametra, $\lambda = 1600$, u praksi je upitna kada je serija ciklička, jer je navedeni rezultat prihvatljiv samo ako je ciklička komponenta (c) proces bijelog šuma. Nije iznenađujuće da je empirijski λ ,

$$\hat{\lambda} = \frac{\sum_{t=1}^T \frac{(\hat{c}_t - \bar{\hat{c}})^2}{T}}{\sum_{t=2}^{T-1} \frac{(\hat{\Delta}^2 g_t - \bar{\hat{\Delta}^2 g})^2}{T-2}}$$

različit od a priori vrijednosti λ ako je serija ciklička. Kada se HP filtar primjenjuje na cikličku seriju, nije potrebno tražiti optimalnu vrijednost λ zasnovanu na Hodrickovim i Prescottovim rezultatima (1980.). Umjesto toga, vrijednost λ mora biti određena u proceduri filtriranja. Kao rezultat kasnijih empirijskih istraživanja preporučuje se vrijednost λ jednaka 100 za godišnje podatke, 1600 za tromjesečne te 14400 za mjesečne. HP filtar je simetričan dvostrani filtar u sredini uzorka, gdje krajnje točke imaju veću težinu. Opažanja koja se nalaze u sredini uzorka dobivaju veoma mali ponder, a posljednje opažanje dobiva veoma visok ponder.

Primjenu HP filtra kritiziralo je više autora. King i Rebelo (1993.) pokazali su da HP filtar, kada se primijeni na velike uzorke, sadrži centrirane četvrte diferencije i čini stacionarnim vremenske serije, koje se diferenciranjem daju pretvoriti u stacionarne, čak i ako su većeg reda integracije. To je nepoželjno svojstvo koje se često zanemaruje. Nema jasnog ekonomskoga razloga zašto ciklički reziduali moraju biti proporcionalni sa četvrtim diferencijama trend-komponente. To dovodi u pitanje primjenu HP filtra. Također je dokazano da je ocijenjeni zbroj kvadrata $\Delta^2 g_t$ veoma cikličan u vremenu, tj. da je HP promjena u stopi rasta često izrazito ciklična.

Harvey i Jaeger (1993.) i Cogley i Nason (1995.) istaknuli su lažnu cikličnost koju stvara HP filtar primijenjen na proces slučajnog hoda (random walk), tj. ako

serija nema cikličku komponentu. Nije začuđujuće ako se tada otkrije lažno cikličko ponašanje, jer se izglađena trend-krivulja primjenjuje na podatke u kojima stvarni trend nije izglađen. Nije dokazano da HP filter generira lažne cikluse ako u seriji postoji ciklička komponenta.

Budući da je praktično nemoguće znati pravu prirodu trend-komponente makroekonomskih serija, razvijena je procedura izdvajanja dominantne cikličke komponente iz serije. U tu je svrhu razvijen MNC (Multivariate Normal Cyclical) filter (Reeves, J. J. i sur., 1996.) kojim se uspješno izdvaja ciklička komponenta serije. Taj pristup izdvajanja cikličke komponente iz serije statistički je opravdan radi upotrebe metode maksimalne vjerodostojnosti uz ograničenja. Mnogo bolju potvrdu postojanja cikličke komponente daje zajednički pristup HP filtra i MNC ocjene, tj. analiza HP cikličkog reziduala i odgovarajuće MNC ocjene dominantne cikličke komponente vremenske serije.

Baxter i King (1995.) nedavno su predložili upotrebu filtra (BK filtra) kojim se uspješno izdvaja komponenta poslovnog ciklusa iz makroekonomske vremenske serije. Usporedbom HP i BK filtera zaključeno je da oba filtra zadovoljavaju pri identifikaciji frekvencija poslovnog ciklusa vremenske serije ako spektar originalne serije ima vrh u tim frekvencijama. No, vrh spektra makroekonomskih vremenskih serija najčešće je u nižim frekvencijama, pa im spektar pri većim frekvencijama monotonno pada. Stoga se uvjeti potrebni za dobru aproksimaciju cikličke komponente uz HP i BK filter malokad susreću u praksi. U većini slučajeva postoji slaganje da se makroekonomska vremenska serija sastoji od stalne i cikličke komponente, tako da će vrh spektra serije biti u nultoj frekvenciji, a vrh spektra cikličke komponente u frekvencijama poslovnog ciklusa. Na primjer, stalna komponenta može biti određena tehnološkim procesom slučajnog hoda s pomakom, a kratkotrajni monetarni i fiskalni šokovi mogu generirati cikličku komponentu s vrhom spektra u frekvencijama poslovnog ciklusa. Ako je to točno, HP filter će uspješno izdvojiti cikličku komponentu.

S izrazito statističkog stajališta, primjena HP filtra na cikličke serije nije potvrđena. HP filtriranje opravdano je samo ako serija sadrži sporo promjenljivi trend i neregularni bijeli šum. Minimizacijom srednje kvadratne greške ili ocjenom metodom maksimalne vjerodostojnosti dokazano je da je HP filter statistički opravdan samo ako je detrendirana serija proces bijelog šuma. U literaturi postoji nova derivacija HP problema minimizacije uz primjenu metode ocjene maksimalne vjerodostojnosti. Time je generaliziran HP problem minimizacije.

Upotreba HP filtra za izdvajanje cikličke komponente makroekonomskih serija nije opravdana, jer u praksi obično nisu zadovoljene ove pretpostavke: (1) Kratkotrajna i stalna komponenta nisu korelirane. (To podrazumijeva da su trend i ciklička komponenta generirane različitim ekonomskim snagama, što je često nekompatibilno s modelima poslovnih ciklusa.) (2) Izvorna je vremenska serija integrirana uz red integracije jednak dva. (To često ne vrijedi za makroekonomske vremenske serije. Obično se pretpostavlja proces kojeg je red integracije jednak jedinici.) (3) Kratkotrajna je komponenta proces bijelog šuma. (To je također upitno.) (4) Parametar kojim se kontrolira izglađenost trenda zadovoljavajući je. (Primjena HP filtra pokazala je da je teško precizno odrediti njegovu vrijednost.)

Nedostatak je HP filtra i to što je odabir parametra izgladivanja arbitrarano, a on utječe na ocjenu. Drugim riječima, informacija o ciklusu mijenja se kako se mijenja parametar izgladivanja. Dalje sumnje o popularnosti HP filtra odnose se na dekompoziciju vremenske serije na trend i ciklus. Na primjer, poznato je da točnost dekompozicije varira ovisno o različitim procesima koji generiraju opažanja i o različitim skupovima opažanja (King i Rebelo, 1993.; Harvey i Jaeger, 1993.). Kydland i Prescott (1990.) naglašavaju da je bilo kakva definicija trenda i ciklusa svakako statistička i da je dekompozicija reprezentacija podataka. Reprezentacija je korisna ako otkriva neki zanimljiv oblik u podacima. Osim toga, HP filter statistički je alat koji ne uzima u obzir ekonomsku ni strukturnu informaciju serije. Laxton i Tetlow (1992.) predložili su prošireni HP filter koji obuhvaća i ekonomsku informaciju, a pripada multivarijantnoj analizi vremenske serije. U ekonomskoj teoriji postoje alternativne metode detrendiranja, npr. Cochraneova metoda (1994.) zasnovana na teoriji permanentnog dohotka i Blanchardova i Quahova (1989.) strukturna dekompozicija. Ciklička se komponenta također može dobiti u univarijantnoj ili multivarijantnoj reprezentaciji uz pomoć Beveridge-Nelsonove (1981.) dekompozicije.

Nažalost, ne postoji konsenzus o najboljem filteru u makroekonomskoj analizi, nego odabir procedure filtriranja mora biti "pokriven" teoretskim modelom.

SIMILARITY MEASUREMENT OF ECONOMIC TRENDS IN CENTRAL EUROPE: BUSINESS CYCLES' CORRELATION OF GERMANY, HUNGARY, THE CZECH REPUBLIC AND CROATIA

Summary

Following the researches done by Laurence Boone and Mathilde Maurel (1998, 1999) about monetary union of Central European countries with Germany or European Union, the research curiosity directed us to discovery of connections of Croatian and German economy, and the average of the European Union. Boone and Maurel (1999) concluded that the benefit of common monetary policy of transitional countries exceeds the costs.

The paper determines only relation of Croatia towards German economy and it is made a comparison with two more progressive transitional countries. Comparison of economy has been carried out by comparison of business cycles, illustrated by unemployment cycle in observed countries. By using the Hodrick-Prescott filter in order to remove trend-components from the time series of unemployment in Germany, Hungary, the Czech Republic and Croatia, the authors proved close correlation of cyclical unemployment movement in all three countries with the cyclical unemployment movement in Germany. Besides, they suggested the similarity of reactions of business cycle in three observed transitional countries during 24 months after initial shock which had originated from German economy, and even larger similarity in reaction to shock during the first 12 months. The authors are careful because the results lead to conclusion that the observed countries in Mundell's sense are optimal currency area. They point out the possibility that cyclical coordination is endogenous, i.e. that it is a consequence of implicit or explicit exchange rate pegging of more progressive transitional countries to exchange rate of German mark during the most of period comprised by analysis (1992-1999). However the paper does not deny the importance of results about cyclical coordination for consideration of optimal currency regime. It is pointed out that the most important in research is the fact that to the already known results about close correlation of cyclical movements in Central Europe is added now the report for Croatia which shows close cyclical correlation of unemployment with Germany.