

UTJECAJ VOLATILNOSTI TEČAJA KUNE NA HRVATSKI IZVOZ

Petar SORIĆ, student*
Ekonomski fakultet, Zagreb

Prethodno priopćenje**
UDK: 336.748(497.5)
JEL: F31

Sažetak

Cilj rada je istražiti funkcioniranje mehanizma monetarnog prijenosa na osnovi utjecaja varijabiliteta tečaja kune na veličinu izvoza. U dosadašnjim se empirijskim studijama za aproksimaciju varijabiliteta tečaja najčešće koristila tzv. historijska volatilnost. Međutim, mnogi makroekonomski vremenski nizovi pokazuju obilježja heteroskedastičnosti, odnosno njihova varianca nije konstantna kroz vrijeme. Stoga je u ovom radu za analizu volatilnosti predložen model uvjetne heteroskedastičnosti, odnosno ARCH model. Kao alternativa ARCH modelu uzeta je i historijska volatilnost, pri čijem računanju nisu korištene samo buduće, već i prošle vrijednosti tečaja. U istraživanju utjecaja volatilnosti tečaja i domaćeg dohotka na veličinu izvoza primijenjen je Johansenov multivarijatni kointegracijski pristup, te model korekcije odstupanja (ECM). Pri tome je odvojeno promatrano njihov kratkoročni i njihov dugoročni odnos. Rezultati ekonometrijske analize pokazuju različitu čvrstoću dugoročne veze volatilnosti i izvoza za dva predložena modela. Prvi model upućuje na blagi negativni utjecaj, a drugi na mnogo jaču averziju hrvatskih izvoznika na volatilnost kao mjeru rizika realnog tečaja kune.

Ključne riječi: ARCH model, Johansenov pristup, ECM model, kointegracija

1. Uvod

Poticanje izvoza elementarni je dio ekonomске, kao i cjelokupne razvojne politike Hrvatske. To je pitanje u nas posebno aktualizirano nedavnim objavljinjem dokumen-

* Autor zahvaljuje anonimnim recenzentima čiji su konstruktivni prijedlozi i kritike pridonijeli kvaliteti članka. Posebnu zahvalu upućuje mentorici dr. sc. Petri Posedel za korisne savjete i stručnu pomoć u vezi s modelom uvjetne heteroskedastičnosti, posebice ARCH modelom.

** Primljeno (Received): 1.6.2007.

Prihvaćeno (Accepted): 30.11.2007.

ta Vlade pod nazivom *Hrvatska izvozna ofenziva* (2007. g.). Naime, loši i stagnirajući hrvatski izvozni rezultati nužno nameću potrebu detaljnijeg analiziranja njegovih komponenti. Stoga ćemo se u ovom radu posebno baviti ispitivanjem postojanja tzv. klasične dihotomije, tj. dvojnosti u hrvatskom gospodarstvu. Osnovno pitanje te dvojnosti jest mogućnost utjecanja na realna gospodarska zbivanja instrumentima i varijablama monetarne politike. Konkretnije, riječ je o tome mogu li se kretanja monetarne politike u obliku manipuliranja tečajem domaće valute preslikati na gospodarsku zbilju. Stoga ćemo u ovom radu analizirati odnos i utjecaj volatilnosti tečaja kune i kretanja domaćeg dohotka na veličinu hrvatskog izvoza. Pritom treba napomenuti da ekonomski teorija daje prilično direktnе i jasne dokaze da domaći dohodak ima snažan pozitivan utjecaj na razinu izvoza, dok je utjecaj volatilnosti tečaja poprilično nejasan i predmet je stalnih istraživanja.

Naime, ekonomski teorija odnosa tih dviju varijabli temelji se na krajnje pojednostavljeno modelu – poduzeću koje, bez uvoza intermedijarnih proizvoda, proizvodi jednu robu te je izvozi na jedinstveno inozemno tržište. Uvezena roba tada je plaćena stranom valutom, a kako poduzeće ne može mijenjati opseg proizvodnje zbog visokih troškova koji se time nameću, veličina profita ovisi isključivo o volatilnosti tečaja. U tom smislu volatilnost se može smatrati rizikom tečaja, pri čemu visoki rizik dovodi do smanjenja izvoza poduzeća (Clark, 1973; Hooper i Kohlhagen, 1978). Empirijska ispitivanja veze volatilnosti tečaja i volumena izvoza ipak nisu rezultirala nedvosmislenim dokazima o smjeru i čvrstoći veze (IMF, 1984; Cote, 1994; Mckenzie, 1999). Jedna hrvatska studija pokazala je da ne postoji nikakva kratkoročna veza između tih dviju varijabli, dok je u dugom roku ona pozitivna (Erjavec, Cota i Bahovec, 2004). Drugim riječima, prema navedenom radu, pokazalo se da aktualna tečajna politika HNB-ova držanja tečaja kune u minimalnim rasponima kretanja nije opravdana jer destimulira izvoz. Stoga je zadatak ovog rada, uvođenjem alternativnih metoda izražavanja volatilnosti tečaja, pokušati dobiti bolje statističke rezultate, koji su ujedno i ekonomski smisleniji, a da istodobno odražavaju i neke od recentnih rezultata istraživanja za volatilnost mnogih makroekonomskih vremenskih nizova.

Pri analiziranju utjecaja volatilnosti tečaja na razinu izvoza za aproksimaciju variabilnosti tečaja često se uzima pomična standardna devijacija stope rasta realnoga efektivnog tečaja (historijska volatilnost) (Brodsky, 1984; Kenen i Rodrick, 1986; Frankel i Wei, 1993; Dell'Ariccia, 1999; Rose, 2000; Erjavec, Cota i Bahovec, 2004). U ovom se radu za analizu volatilnosti predlažu dva alternativna modela. Konkretno, prvi je model ARCH(1), koji je uveden radi prevladavanja problema homoskedastičnosti (Engle, 1982). Drugi je model zapravo modifikacija same historijske volatilnosti.

Rad je koncipiran u četiri dijela. Nakon uvoda, u kojemu se iznose argumenti za opravdanost izučavanja problematike izvoza i njegovih determinanti, slijede detaljnija objašnjenja metodologije i razloga primjene ARCH modela, kao i ostalih ekonometrijskih tehniki upotrijebljenih u radu. Potom se analiziraju empirijski rezultati dobiveni analizom podataka o trima primijenjenim varijablama (volatilnost tečaja, domaći dohodak i izvoz). Analizirano je kako različita modeliranja rizika realnoga efektivnog tečaja mogu utjecati na njegovu vezu s izvozom. Rad završava rezimiranjem dobivenih rezultata i njihovim ekonomskim implikacijama te smjernicama za daljnja istraživanja.

2. Metodološki pristup

U mnogim se empirijskim analizama za aproksimaciju varijabiliteta tečaja primjenjuje standardna, historijska volatilnost. Ona se matematički može izraziti ovako (Kenen i Rodrick, 1986):

$$V_t = \left[\frac{1}{m} \sum_{i=1}^m (\ln E_{t+i-1} - \ln E_{t+i-2})^2 \right]^{\frac{1}{2}} \quad (1)$$

pri čemu je E_t realni efektivni tečaj.

Vrijednosti dobivene uvrštanjem empirijskih podataka za realni efektivni tečaj u tu relaciju zapravo su niz jednostavnih pomičnih prosjeka, koji se definiraju kao aritmetičke sredine m uzastopnih članova vremenskog niza. One služe za izglađivanje vremenskog niza. Ekonomski logika te formule zapravo upućuje na to da trenutačnu vrijednost volatilnosti u trenutku t (V_t) zapravo određuje prosjek njegovih m idućih uzastopnih vrijednosti. Osnovna pretpostavka takve formulacije volatilnosti jest homoskedastičnost. Ipak, mnogi financijski i makroekonomski vremenski nizovi imaju tendenciju izrazito velikih raspona volatilnosti u određenim vremenskim razdobljima. Praktično gledano, ako je varijanca promatranog niza volatilnosti tečaja heteroskedastična, to bi značilo da bi i procjena parametara u modelu mogla biti neefikasna ako se pritom ne modelira i uvjetna heteroskedastičnost promatranog niza.

Mnoga empirijska istraživanja potvrdila su da sofisticiraniji modeli za procjenu volatilnosti poput ARCH, GARCH ili EGARCH modela dovode do točnijih i boljih statističkih procjena (Akgiray, 1989; Chu i Freud, 1996). Stoga bi radi kvalitete rezultata ekonometrijske analize za predikciju volatilnosti (u našem promatranom primjeru realnoga efektivnog tečaja) bilo poželjno primijeniti heteroskedastični model u kojemu varijanca ovisi o prošlim vrijednostima samog niza. Prvi modeli za empirijsku analizu volatilnosti potječu iz financijskih analiza. Tako je promatranjem vremenskih nizova logaritama povrata nekih američkih dionica utvrđeno da ih karakteriziraju serijska ovisnost podataka i promjena volatilnosti kroz vrijeme, te da je distribucija podataka asimetrična i da ima zadebljane repove¹. Drugim riječima, podaci ne potječu iz normalne distribucije, zanemarena je heteroskedastičnost varijance pa stoga takav model nije realističan za izražavanje volatilnosti. Prvi sofisticiraniji model uveden je pod nazivom *autoregresijski uvjetno heteroskedastični model* ili, kraće, ARCH (Engle, 1982; Engle, 1980), u kojemu uvjetna varijanca nije konstantna kroz vrijeme i pokazuje autoregresijsku strukturu.² U ARCH modelima svako je opažanje (X_t) jednakom umnošku procesa bijelog šuma (Z_t) i pozitivnog procesa σ_t , uz pretpostavku da su za svaki t varijable Z_t i σ_t nezavisne:

¹ To su tzv. stilizirane činjenice financijskih podataka.

² U empirijskim radovima često se pokazuje da se GARCH(1,1) procesom može prezentirati većina vremenskih nizova, te da su skupovi podataka koji zahtijevaju modeliranje procesa reda većega od GARCH(1,2) ili GARCH(2,1) zaista rijetkor (Berra, Higgins, 1993). Stoga je u ovom radu prvotno u obzir bio uzet GARCH(1,1) model. Ipak, pri procjeni parametara pokazalo se da je drugi parametar u modelu jednak nuli, pa se takav model zapravo sveo na ARCH(1) (Jondeau, Rockinger, 2007). Zato je u radu analiziran samo ARCH(1) model kao jedan od mogućih alternativnih pristupa za izražavanje volatilnosti.

$$X_t = Z_t \sigma_t \quad (2)$$

Uz pretpostavku gaussovskoga bijelog šuma, tj. $Z_t \sim N(0, I)$, ARCH (q) proces definiра se kao:

$$\sigma_t^2 = \alpha_0 + \alpha_1 X_{t-1}^2 + \dots + \alpha_q X_{t-q}^2, \text{ za svaki } t \quad (3)$$

uz uvjete na parametre $\alpha_0, \alpha_i > 0, i = 1, \dots, q$.

Obilježje takvog ARCH procesa jest postojanje *uvjetne varijance* σ_t , koja ovisi o vlastitim prošlim vrijednostima, tj. njezino izračunavanje uvjetujemo na informacije dostupne do trenutka t . Drugim riječima, možemo reći da se model temelji na svojstvu heteroskedastičnosti, što karakterizira i sve makroekonomski vremenske nizove kojima se koristimo u analizi. Ta je heteroskedastičnost ujedno bila i osnovni razlog uvođenja ARCH(1) modela za izražavanje volatilnosti tečaja u tu analizu. Ako s Y_t označimo $\log(E_t)$, pri čemu je E_t realni efektivni tečaj kune prema euru, relacije (2) i (3) mogu se u obliku ARCH(1) modela potrebnoga za procjenu volatilnosti realnoga efektivnog tečaja izraziti ovako:

$$Y_t = C + V_t Z_t \quad (4)$$

$$V_t^2 = \omega + \alpha(Y_{t-1} - C)^2 \quad (5)$$

pri čemu vrijedi

$$\omega > 0 \text{ i } \alpha > 0, \text{ te } \alpha \leq 1 \quad (6)$$

Prema Jondeau, Rockinger, Poon (2006) slijedi da je za ARCH(1) model nužan i dovoljan uvjet da proces V_t^2 bude jako stacionaran:

$$E[\ln(\alpha Z_t^2)] > 0 \quad (7)^3$$

Jedna od ključnih prednosti ARCH modela jest mogućnost procjene određenih vrijednosti za jedno promatrano vremensko razdoblje unaprijed, tj. u kontekstu ovog rada vrijednosti volatilnosti V_{t+1} na temelju podataka dostupnih do trenutka t .

Procjena promatranog modela temelji se na 132 mjesечna podatka za realni efektivni tečaj kuna/euro od siječnja 1996., zaključno s prosincem 2006. godine. Prema pretpostavci, Z_t je niz nezavisnih, jednakosti distribuiranih slučajnih varijabli takvih da $Z_t \sim N(0, I)$, pa funkcija vjerodostojnosti ima oblik:

$$L_t = \frac{1}{T} \sum_{i=1}^T \left[-\frac{1}{2} \ln(2\pi) - \frac{1}{2} \ln(V_t^2) - \frac{1}{2} \frac{Y_t}{V_t^2} \right] \quad (8)$$

pri čemu je T broj opaženih podataka.

³ Može se odmah primijetiti da je uz $\alpha = 1$ uvjet (7) ispunjen.

Označimo vektor nepoznatih parametara s $\theta = (C, \omega, \alpha)$. Potrebno je pronaći vektor θ za koji funkcija L postiže maksimalnu vrijednost uz uvjete dane u relaciji (6). Maksimizacija funkcije L , postiže se pomoću numeričkog algoritma za traženje maksimuma funkcije uz dane uvjete na parametre. U tablici 1. prikazane su njihove procijenjene vrijednosti.⁴

Tablica 1. Procijenjeni parametri ARCH(1) modela

Parametar	Vrijednost	Stand. pogreška	t-vrijednost
C	4,5613	0,0021	2170,6687
ω	$7,04 \cdot 10^{-5}$	$4,67 \cdot 10^{-5}$	1,5903
α	1	0,36297	2,7551

Izvor: izračun autora

Pritom je iz ekonometrijske analize vidljivo da je procijenjena vrijednost za parametar α jednaka 1, što upuće na nestacionarnost promatrano vremenskog niza. Iz toga proizlazi da će s povećanjem vremena t bezuvjetna varijanca modela težiti beskonačnosti, za što se u ekonometrijskoj literaturi obično kaže da niz "eksplodira".

U ekonomskom smislu činjenica da je $\alpha = 1$ mogla bi se objasniti time da, u srednjem, proces Y_t (logaritam realnoga efektivnog tečaja kune) karakteriziraju izrazito velike oscilacije u kratkim razdobljima.

Navedena nestacionarnost kasnije će biti dodatno potkrijepljena i rezultatima testova jediničnih korijena. Dakle, vremenski niz volatilnosti dobiven ARCH modelom pokazuje obilježja nestacionarnosti. Postojanje jediničnog korijena u uvjetnoj varijanci ne utječe na raspodjelu procjenitelja jer su oni i u tom slučaju normalno distribuirani, zbog čega je moguće donošenje zaključaka o modelu na temelju standardnih test veličina (Lumsdaine, 1996). Imajući na umu aktualnost i esencijalnu važnost analiziranja izvoza i njegovih determinanti u Hrvatskoj, odlučili smo tako dobivenu volatilnost uključiti u analizu.

Drugi predloženi alternativni način analize volatilnosti dan je jednadžbom:

$$V_t = \left[\frac{1}{2m+1} \sum_{i=-m}^m (\ln E_{t+i} - \ln E_{t+i-1})^2 \right]^{\frac{1}{2}} \quad (9)$$

Iz navedene je relacije vidljivo da se za izračun jednog podatka iz niza V12 koristi 12 uzastopnih vrijednosti realnog tečaja koje mu vremenski prethode, te 12 idućih vrijednosti. Uvođenje takve formulacije volatilnosti opravdano je potrebom nositelja monetarne politike da odluke donose i na temelju dotadašnjih kretanja tečaja, a ne isključivo njegovih budućih vrijednosti (kao u relaciji 1).

⁴ Parametri su dobiveni primjenom programskog paketa Matlab.

Osnovni razlog za uvođenje tih dvaju alternativnih modela volatilnosti u analizu utjecaja varijabiliteta tečaja kune na veličinu izvoza jest činjenica da je njihova primjena metodološka inovacija u izučavanju odnosa tih dviju varijabli u Hrvatskoj. Krajnji cilj koji želimo postići takvim korakom jest eventualno dobivanje boljih statističkih rezultata za ocjenu veze volatilnosti tečaja i razine izvoza.

Nakon volatilnosti tečaja, druga nezavisna varijabla u primjenjenome modelu jest obujam industrijske proizvodnje, koja, dokazano, može služiti kao dobar pokazatelj za ukupnu ekonomsku aktivnost u nekoj zemlji. Naime, unatoč tome što se udio industrijske proizvodnje u ukupnoj proizvodnji tijekom proteklih petnaest godina smanjio, kratkoročna varijabilnost tog pokazatelja ciklički prati i izuzetno dobro predočuje kretanje realnoga hrvatskog BDP-a (Cerovac, 2005).

Također moramo napomenuti da podaci o zavisnoj varijabli u promatranome modelu (veličina realnog izvoza) u hrvatskoj službenoj statistici ne postoje. Stoga smo kao aproksimaciju za razinu izvoza iskoristili nominalni izvoz roba i usluga u nacionalnoj valuti, tj. u kuni. Podaci za sve tri navedene varijable mjesečna su slika i odnose se na razdoblje siječanj 1996 – prosinac 2006.

Budući da želimo ispitati funkcionalnu ovisnost opsega izvoza o industrijskoj proizvodnji i volatilnosti tečaja, promatrani model označit ćemo:

$$\text{izvoz} = f(\text{ind}, \text{Vol}) \quad (10)$$

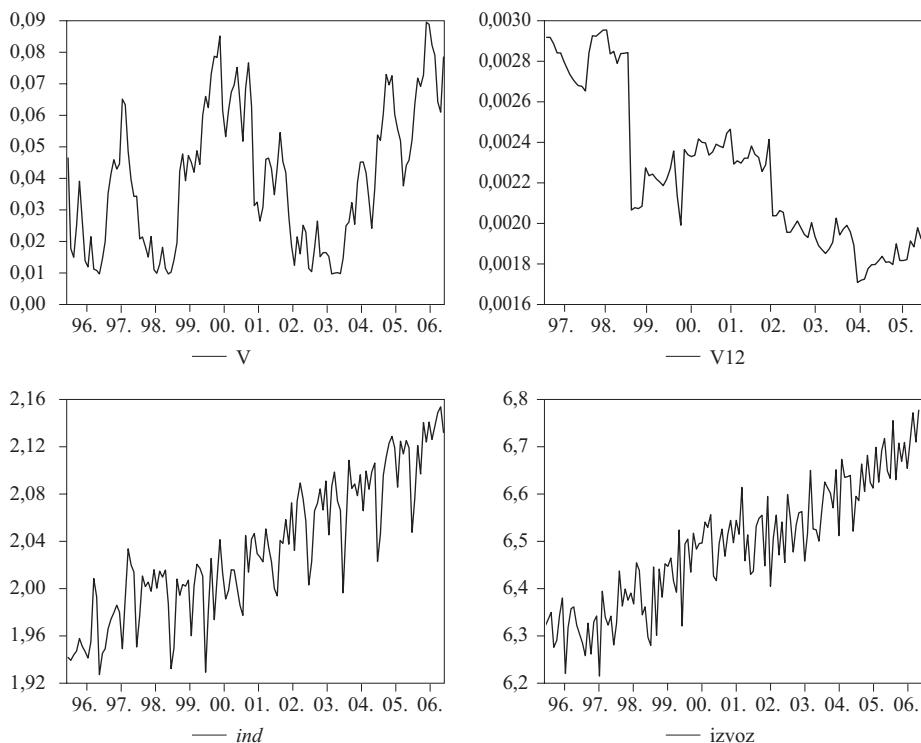
pri čemu su vrijednosti niza *ind* izražene u obliku indeksa na stalnoj bazi (prosjek 2000 = 100), a podaci za realni tečaj kuna/euro, korišteni za oba niza volatilnosti, također su u obliku indeksa, s 2001. kao baznom godinom. Pritom *izvoz* i *ind* označavaju logaritamske vrijednosti istoimenih vremenskih nizova.

Većina makroekonomskih vremenskih nizova po prirodi je nestacionarna (Asteriou, 2006). Jedan od uzroka nestacionarnosti vremenskog niza može biti prisutnost jediničnog korijena pa primjena klasične linearne regresije na takvom nizu može dovesti do previšokih vrijednosti R^2 i *t*-statistike (tzv. *spurious regression*). Tada su nam na raspolaganju sofisticirane ekonometrijske tehnike poput Engle-Grangerova ili Johansenova pristupa. Obje navedene tehnike baziraju se na načelu kointegracije, tj. postojanja dugoročne veze između dviju ili više varijabli, ali Johansenov je pristup multivarijatan i dopušta postojanje više od jednoga kointegracijskog vektora (Johansen, 1991). Stoga smo se odlučili upravo za taj pristup.

3. Empirijski podaci

Kao prvi korak i početak ispitivanja kointegracije, tj. postojanja dugoročnog odnosa među promatranim varijablama, potrebno je utvrditi jesu li svi promatrani integrirani vremenski nizovi istog reda. U stacionarnim vremenskim nizovima efekti kratkoročnih šokova su uklonjeni i nizovi se vraćaju svojoj srednjoj vrijednosti (Asteriou, 2006). Kako je na slici 1. vidljivo da ni za jedan od četiri promatrana vremenska niza to nije slučaj, takav grafički prikaz može upućivati na nestacionarnost nizova od interesa. To će potvrditi i provedeni formalni test jediničnih korijena.

Slika 1. Prikazi vremenskih nizova od interesa u razinama



Izvor: izračun autora

Za empirijsku analizu proveden je ADF⁵ test jediničnih korijena (Dickey-Fuller, 1979), koncipiran na način da nulta hipoteza (H_0) podrazumijeva nestacionarnost, tj. postojanje jediničnog korijena u vremenskom nizu od interesa.

Tablica 2. ADF test u razinama

Naziv varijable	Konstanta i trend	Konstanta	Model bez konstante i trenda
izvoz	-2,107934 (11)	-0,934560 (11)	3,519571 (11)
ind	-1,324893 (12)	1,277858 (12)	3,451840 (12)
V12	-3,252733 (0)	-1,956908 (0)	-1,183389 (0)
V	-2,813696 (1)	-1,988642 (2)	-0,416649 (2)

Izvor: izračun autora

⁵ Svi podaci dobiveni su primjenom programskog paketa E-Views i Mackinnonovih tablica kritičnih vrijednosti (1996. g.).

Tablica 3. ADF test u prvim diferencijama

Naziv varijable	Konstanta i trend	Konstanta	Model bez konstante i trenda
Δizvoz	-5,695471*(10)	-5,706614*(10)	-2,753500*(12)
Δind	-5,739134*(11)	-5,415932*(11)	-2,990529*(12)
ΔV12	-11,18570* (0)	-11,20553* (0)	-11,17002* (0)
ΔV	-9,246821* (1)	-9,273375* (1)	-9,281676* (1)

Napomena: Vrijednosti označene s * upućuju na odbacivanje nulte hipoteze nestacionarnosti pri 5-postotnoj značajnosti.

Izvor: izračun autora

Stoga možemo reći da rezultati testa upućuju na zaključak da su sve promatrane varijable integrirane, i to da su prvog reda, tj. I(1)⁶, odnosno nestacionarne u razinama, a stacionarne u prvim diferencijama, pa možemo nastaviti s testiranjem kointegracije. Bitno je napomenuti da će se u dalnjim analizama zasebno promatrati dva modela. Prvi, u kojem za procjenu volatilnosti služi ARCH model (vremenski niz V), te drugi, u kojem se za isto to rabi modifikacija historijske volatilnosti, odnosno prosječna usrednjena standardne devijacije 12 prethodnih i 12 idućih vrijednosti stope rasta realnog efektivnog tečaja (vremenski niz V12). Stoga ćemo započeti prvim modelom.

Sukladno dobivenim rezultatima ADF testa, VAR (vektorski autoregresivni) model s uključenim svim varijablama, dan je jednadžbom (Harris, 1995):

$$Z_t = A_1 Z_{t-1} + A_2 Z_{t-2} + \dots + A_k Z_{t-k} + \psi D_t + u_t \quad (11)$$

pri čemu je Z vektor svih n varijabli sustava (u promatranom primjeru varijabli *izvoz*, *ind* i *Vol*), a u_t označava n dimenzionalni vektor grešaka relacije s nultom srednjom vrijednošću i matricom kovarijanci Σ . Vektor D , sadržava 11 *dummy varijabli* upotrijebljenih u modelu radi prevladavanja sezonskih utjecaja. Takav VAR model dan je općenito, dok ćemo optimalan broj pomaka za varijable u VAR modelu (11) dobiti provođenjem odgovarajućeg testa. Vodeći se Akaike informacijskim kriterijem, zaključili smo kako je za promatrani model optimalan broj pomaka 3.

Varijable su kointegrirane ako i samo ako možemo reformuliranjem jednadžbe (11) definirati tzv. VECM (vektorski model korekcije odstupanja) (Asteriou, 2006):

$$\Delta Z_t = \Gamma_1 \Delta Z_{t-1} + \Gamma_2 \Delta Z_{t-2} + \dots + \Gamma_{k-1} \Delta Z_{t-k+1} + \Pi Z_{t-1} + \psi D_t + u_t \quad (12)$$

Matrica Π još se dodatno može zapisati kao

$$\Pi = \alpha x \beta' \quad (13)$$

⁶ U zgradama je nakon svake test-vrijednosti dan optimalan broj pomaka za pojedinu varijablu, dobiven pomoću Akaike informacijskog kriterija (Asteriou, 2006).

pri čemu je α matrica brzine prilagodbe ravnotežnim koeficijentima. Naime, zbog određenih negativnih šokova ekonomija se pomiče iz dugoročne ravnoteže, a koeficijenti matrice α mjere brzinu njezina povratka u stanje ekvilibrija. Pritom je β' matrica dugoročnih koeficijenata, tj. odnosa varijabli u dugoročnoj ravnoteži.

Jedan od najznačajnijih koraka kointegracijske analize jest utvrđivanje ranga dugoročne matrice Π , odnosno utvrđivanje maksimalnoga broja njezinih linearno neovisnih kolona. Naime, taj broj zapravo označava broj kointegracijskih vektora. Postoje dvije vrste test-veličina za određivanje broja kointegracijskih vektora: test-veličina traga matrice svojstvenih vrijednosti (*trace*) i test-veličina najveće svojstvene vrijednosti (*maximum eigenvalue*). Prva testira nultu hipotezu da je broj vektora manji ili jednak r , nasuprot alternativnoj hipotezi da je jednak k , pri čemu je k broj endogenih varijabli. Za drugu test-veličinu H^0 znači da je $r = 0$, nasuprot alternativnoj, koja govori da je $r = 1$, zatim $r = 1$ nasuprot $r = 2$, itd. Rezultati određivanja broja kointegracijskih vektora dani su u sljedećim tablicama.

Tablica 4. Određivanje broja kointegracijskih vektora (test-veličina trace)

$H_0: r =$	Eigenvalue	Test-veličina <i>trace</i>	Kritična vrijednost 0,05	Kritična vrijednost 0,1
0	0,184941	40,36490 ^a	42,91525	39,75526
1	0,082896	14,18963	25,87211	23,34234
2	0,024028	3,113155	12,51798	10,66637

^a Označava odbacivanje nulte hipoteze pri 10-postotnoj razini značajnosti.

Izvor: izračun autora

Tablica 5. Određivanje broja kointegracijskih vektora (test-veličina maximum eigenvalue)

$H_0: r =$	Eigenvalue	Test-veličina <i>max. eigen</i>	Kritična vrijednost 0,05	Kritična vrijednost 0,1
0	0,184941	26,17527 ^a	25,82321	23,44089
1	0,082896	11,07647	19,38704	17,23410
2	0,024028	3,113155	12,51798	10,66637

^a Označava odbacivanje nulte hipoteze pri 5-postotnoj razini značajnosti.

Izvor: izračun autora

U tom slučaju obje vrijednosti upućuju na zaključak da je dugoročni odnos promatranih varijabli određen jednim kointegracijskim vektorom.

Također je proveden i test o uključivanju determinističkih elemenata u model, a do biveni su rezultati dani u sljedećoj tablici.

Tablica 6. Uključivanje determinističkih elemenata u model⁷

Kointegracijska jednadžba	Konstanta	Konstanta	Konstanta i linearni trend
VAR	–	Konstanta	Konstanta
Broj jednadžbi	<i>trace</i>	0	0
	<i>max. eigen</i>	0	1

Izvor: izračun autora

Pošto oba indikatora (test-veličina traga matrice svojstvenih vrijednosti i test-veličina najveće svojstvene vrijednosti) upućuju na postojanje konstante i trenda u kointegracijskoj jednadžbi, možemo je izraziti jednadžbom:

$$\text{izvoz} = -7,589764 - 0,003994 t + 0,689808 \text{ ind} - 0,860479 V \quad (14)$$

Iz nje možemo zaključiti kako je izvoz u Hrvatskoj pozitivno koreliran s veličinom domaćeg dohotka, dok je njegova veza s volatilnošću tečaja negativna. Pritom na temelju *t*-vrijednosti za *ind* (1,60540) i *V* (-3,56157) možemo zaključiti kako je pri 10-postotnoj razini signifikantnosti utjecaj volatilnosti, kao i utjecaj opsega industrijske proizvodnje, statistički značajan. Visoka *t*-vrijednost trenda (-6,68589) govori da je i trend statistički značajan, i to pri 10-postotnoj razini signifikantnosti.

Koristeći se kointegracijskim vektorom možemo definirati model korekcije odstupanja:

$$\Delta \text{izvoz} = \varsigma_1 + \sum_{i=1}^3 b_i \Delta \text{izvoz}_{t-i} + \sum_{i=1}^3 c_i \Delta \text{ind}_{t-i} + \sum_{i=1}^3 d_i \Delta V_{t-i} + \alpha_1 \text{ECM}_{t-1} + \sum_{i=1}^{11} g_i D_{t-i} + u_t \quad (15)$$

pri čemu su D_{t-i} sezonske *dummy variable* uvedene radi rješavanja problema sezonalnosti u podacima. Parametar ECM osigurava konvergenciju modela dugoročnom ekvilibriju, a α_1 je koeficijent koji odražava brzinu prilagodbe tom stanju dugoročne ravnoteže. Procjene parametara iz VEC modela dati su u tablici 7.

Kako je VECM model aproksimacija kratkoročne funkcije izvoza, na temelju *t*-vrijednosti ECM koeficijenta ($t = -4,27997$) možemo zaključiti kako je član korekcije pogreške pri 5% statistički značajan. Parametar uz ECM ($\alpha_1 = -0,757946$) govori da se mjesечно korigira 75,79% odstupanja od ravnotežnog stanja. No *t*-vrijednost za ΔV_{t-1} ($t = -2,14512$) sugerira kako je kratkoročni odnos promjene volatilnosti tečaja i izvoza unutar tog modela pri 5-postotnoj razini značajnosti određen samo vremenskim pomakom za jedan mjesec unatrag. Toliko je, naime, opseg izvoza osjetljiv na promjene volatilnosti samog tečaja.

Iako utvrđivanje ranga dugoročne matrice Π daje odgovor o broju kointegracijskih jednadžbi, potrebno ga je upotpuniti analizom slabe egzogenosti varijabli u modelu. Naime,

⁷ Primjenjena je MacKinnon-Haug-Michelisova tablica kritičnih vrijednosti (1999).

sve smo varijable dosad promatrali kao potencijalno endogene. Stoga je za ispitivanje slabe egzogenosti proveden χ^2 -test, kojim se provjerava je li parametar prilagodbe (koefficijent iz α matrice) za promatranoj varijablu u VEC modelu jednak nuli (Harris, 1995). Naime, ako se prihvati nulta hipoteza χ^2 -testa, možemo konstatirati da je ta varijabla slabo egzogena.

Tablica 7. VECM model

Varijabla	Koeficijent	t-vrijednost	Varijabla	Koeficijent	t-vrijednost
ζ	0,006287	0,35300	D_{t-1}	-0,077519	-3,30510
$\Delta izvoz_{t-1}$	-0,331254	-2,02016	D_{t-2}	-0,047702	-1,40771
$\Delta izvoz_{t-2}$	-0,134547	-0,96135	D_{t-3}	0,034553	0,99283
$\Delta izvoz_{t-3}$	-0,034325	-0,35165	D_{t-4}	0,025413	0,84337
Δind_{t-1}	0,054044	0,19015	D_{t-5}	-0,003448	-0,15848
Δind_{t-2}	0,093412	0,31812	D_{t-6}	-0,007162	-0,34057
Δind_{t-3}	0,405528	1,49440	D_{t-7}	0,031083	1,38548
ΔV_{t-1}	-1,087370	-2,14512	D_{t-8}	-0,050553	-2,44957
ΔV_{t-2}	-0,347279	-0,70503	D_{t-9}	0,010997	0,45026
ΔV_{t-3}	-0,350109	-0,71238	D_{t-10}	0,051901	2,10260
ECM	-0,757946	-4,27997	D_{t-11}	0,013952	0,59721

Izvor: izračun autora

Tablica 8. Testiranje slabe egzogenosti varijabli

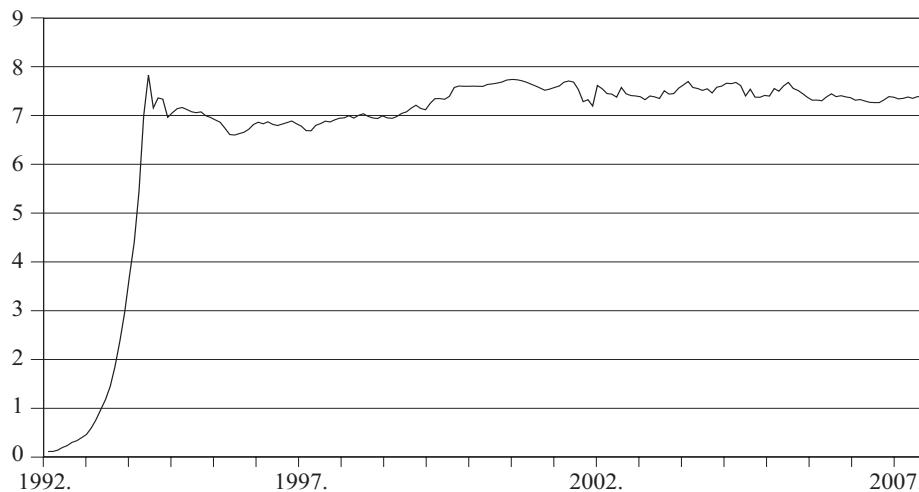
Naziv varijable	izvoz	ind	V
test-veličina	$\chi^2 = 12,93052$	$\chi^2 = 5,536632$	$\chi^2 = 0,852173$
p-vrijednost	0,000323	0,018622	0,355938

Izvor: izračun autora

Dobivene p -vrijednosti i χ^2 -statistika nedvosmisleno upućuju na zaključak da su *izvoz* i *ind* endogene varijable, dok je volatilnost *V* slabo egzogena. Dakle, volatilnost tečaja neznatno reagira samo na odstupanje od dugoročne ravnoteže između varijabli u modelu.⁸ Takvi rezultati zapravo i nisu iznenađujući s obzirom na činjenicu da HNB, pod pritiskom maastrichtskih kriterija, vodi monetarnu politiku u vrlo uskom rasponu dopuštenog kretanja tečaja. Naime, promotrimo li kretanje tečaja kn/EUR posljednjih 15 godina, vidjet ćemo da je on od stabilizacijskog programa iz listopada 1993. praktički održavan na fiksnoj razini (HNB, 2007).

⁸ Slične rezultate potvrđuju i drugi radovi. Za detaljniji prikaz vidjeti: Vizek, 2006.

Slika 2. Srednji devizni tečaj HNB-a na kraju razdoblja siječanj 1992 – travanj 2007.



Izvor: izračun autora

Sada promotrimo drugi model, u kojem volatilnost izražavamo kao modifikaciju historijske volatilnosti. U njemu, dakle, takvu aproksimaciju volatilnosti označavamo sa V12. Uz prethodno dokazanu činjenicu da je ta varijabla $V12 \sim I(1)$, u dalnjem se koraku analizira optimalan broj pomaka u VAR modelu. Kao i u prethodnome modelu, i u ovome kriteriji za dužinu pomaka sugeriraju 3 kao optimalan broj. Treći korak Johansenove procedure i u promatranom je modelu određivanje broja kointegracijskih jednadžbi.

Tablica 9. Određivanje broja kointegracijskih vektora (test-veličina trace)

$H_0: r =$	Eigenvalue	Test-veličina trace	Kritična vrijednost 0,05	Kritična vrijednost 0,1
0	0,214373	47,70672 ^a	42,91525	39,75526
1	0,134460	19,60371	25,87211	23,34234
2	0,043895	4,33089	12,51798	10,66637

^a Označava odbacivanje nulte hipoteze pri 5-postotnoj značajnosti.

Izvor: izračun autora

Tablica 10. Određivanje broja kointegracijskih vektora (test-veličina maximum eigenvalue)

$H_0: r =$	Eigenvalue	Test-veličina max. eigen	Kritična vrijednost 0,05	Kritična vrijednost 0,1
0	0,214373	28,10301 ^a	25,82321	23,44089
1	0,134460	15,27284	19,38704	17,23410
2	0,043895	4,330869	12,51798	10,66637

^a Označava odbacivanje nulte hipoteze pri 5-postotnoj značajnosti.

Izvor: izračun autora

Obje test-veličine (*trace* i *maximum eigenvalue*) upućuju na postojanje samo jednoga kointegracijskog vektora, a rezultati testa o uključivanju determinističkih elemenata dani u sljedećoj tablici potvrđuju potrebu uključivanja linearног trenda i konstante.

Tablica 11. Uključivanje determinističkih elemenata u model⁹

Kointegracijska jednadžba	Konstanta	Konstanta	Konstanta i linearni trend
VAR	–	Konstanta	Konstanta
Broj jednadžbi	<i>trace</i>	0	1
	<i>max. eigen</i>	0	1

Izvor: izračun autora

Stoga navedena kointegracijska jednadžba izgleda ovako:

$$\text{izvoz} = -10,56368 - 0,007272 t + 2,326924 \text{ ind} - 117,3238 \text{ V12} \quad (16)$$

Dobivene *t*-vrijednosti (-8,60845 za *t*, 4,92680 za *ind* i -3,32224 za *V12*) pokazuju da su sve tri varijable u modelu u dugom roku značajne. Procijenjeni utjecaj domaćeg dohotka očekivano je ponovno pozitivan. Međutim, intrigira izuzetno velik negativan utjecaj volatilnosti na opseg izvoza. Takvi rezultati očito govore da hrvatski izvoznici izrazito negativno reagiraju na povećanje volatilnosti. Drugim riječima, posljedica povećanja rizika realnoga efektivnog tečaja u promatranom je razdoblju bilo smanjenje izvoza.

Procijenjena kointegracijska jednadžba izražava se sljedećim izrazom:

$$\Delta \text{izvoz} = \zeta_1 + \sum_{i=1}^3 b_i \Delta \text{izvoz}_{t-i} + \sum_{i=1}^3 c_i \Delta \text{ind}_{t-i} + \sum_{i=1}^3 d_i \Delta V_{t-i} + \alpha_1 \text{ECM}_{t-1} + \sum_{i=1}^{11} g_i D_{t-i} + u_t \quad (17)$$

U sljedećoj su tablici dani i procijenjeni parametri iz prethodne jednadžbe.

Tablica 12. VECM model

Varijabla	Koeficijent	<i>t</i> -vrijednost	Varijabla	Koeficijent	<i>t</i> -vrijednost
ζ	-0,009858	-0,46432	D_{t-1}	-0,087964	-3,09002
$\Delta \text{izvoz}_{t-1}$	-0,711433	-3,56114	D_{t-2}	-0,024136	-0,57571
$\Delta \text{izvoz}_{t-2}$	-0,467361	-2,55494	D_{t-3}	0,080059	1,76756
$\Delta \text{izvoz}_{t-3}$	-0,158888	-1,29776	D_{t-4}	0,068921	1,64257
Δind_{t-1}	0,112195	0,24613	D_{t-5}	0,017258	0,56464
Δind_{t-2}	0,426054	1,03057	D_{t-6}	0,002205	0,08751
Δind_{t-3}	0,615321	1,74282	D_{t-7}	0,040842	1,50557
$\Delta V12_{t-1}$	-13,43439	-0,28750	D_{t-8}	-0,017665	-0,71882
$\Delta V12_{t-2}$	78,09946	1,69311	D_{t-9}	0,037621	1,31631
$\Delta V12_{t-3}$	-29,28236	-0,62879	D_{t-10}	0,0069820	2,31139
ECM	-0,278838	-1,48725	D_{t-11}	0,022028	0,75151

Izvor: izračun autora

⁹ Primjenjena je MacKinnon-Haug-Michelisova tablica kritičnih vrijednosti (1999).

Niske t -vrijednosti za volatilnost pri sva tri pomaka govore da, za razliku od dugoga, u kratkom roku ne postoji statistički signifikantan utjecaj volatilnosti tečaja na opseg izvoza.

Tablica 13. Testiranje slabe egzogenosti varijabli

Naziv varijable	izvoz	ind	V12
test-veličina	$\chi^2 = 1,353201$	$\chi^2 = 10,07904$	$\chi^2 = 5,042692$
p-vrijednost	0,244719	0,001500	0,024730

Izvor: izračun autora

Ovi su rezultati testa slabe egzogenosti nešto drugačiji. Na temelju takve procjene volatilnosti, ona se pokazala endogenom varijablom. Međutim, na temelju visoke χ^2 statistike i p -vrijednosti izvoz se može smatrati slabo egzogenom varijablom, što zapravo pokazuje da postoji i veza u drugom smjeru, tj. da bi se volatilnost tečaja trebala promatrati kao funkcija izvoza. Iz takvih je rezultata vidljivo da je za dokazivanje veze između volatilnosti i izvoza iznimno bitan način modeliranja same volatilnosti.

4. Zaključak

Cilj ovog rada bio je ekonometrijskom analizom ispitati funkcioniranje mehanizma monetarnog prijenosa u Hrvatskoj. Točnije, doveden je u pitanje utjecaj monetarne politike na realna kretanja gospodarstva (opseg izvoza) putem manipulacije tečajem. Za tu su svrhu pri procjeni volatilnosti tečaja ponuđena dva modela: uvjetno heteroskedastični, tj. ARCH(1) model, i modifikacija standardne formule za procjenu volatilnosti. Uvedena modificirana formula za volatilnost ne uzima u obzir samo buduće vrijednosti tečaja, već i one prošle, te se takvim modelom nastoji predvidjeti neka vrijednost u skorijoj budućnosti.

Dugoročna veza između volatilnosti dobivene pomoću ARCH(1) modela i izvoza pokazala se negativnom, ali prilično malom, što znači da hrvatski izvoznici na *povećanje* volatilnosti tečaja kune reagiraju malim, ali postojećim *smanjenjem* izvoza. Konkretno, 1-postotno povećanje volatilnosti, *ceteris paribus*, u promatranom bi modelu rezultiralo smanjenjem izvoza za 0,86%. Može se, dakle, zaključiti da hrvatski izvozni sektor karakterizira averzija prema riziku realnog tečaja kune. Takvi se rezultati potpuno podudaraju s ekonomskom teorijom (Clark, 1973; Hooper i Kohlhagen, 1978), ali su u kontradikciji s jedinim autoru poznatim hrvatskim empirijskim istraživanjem te tematike (Erjavec, Cota i Bahovec, 2004). Nadalje, test slabe egzogenosti varijabli u tome modelu upozorio je na činjenicu da se volatilnost mora promatrati kao slabo egzogena varijabla, što znači da ona u promatranom vremenskom razdoblju nije pokazala sposobnost da se u kratkom roku prilagodi odstupanjima od dugoročne ravnoteže. Jednako tako, u kratkom se roku pokazalo da je veza između promjene volatilnosti tečaja i izvoza također negativna, te statistički značajna samo za jedan mjesec unatrag.

Kada je, pak, riječ o dugoročnom odnosu između modifikacije historijske volatilnosti (V12) i izvoza, ona pokazuje da je procijenjeni koeficijent elastičnosti izvoza s obzirom

na volatilnost tečaja vrlo visok i iznosi čak -117,3238. Dakle, taj podatak dodatno potvrđuje činjenicu da povećanje volatilnosti tečaja kune obeshrabruje hrvatske izvoznike, pa na nj reagiraju smanjenjem opsega izvoza. U tom se smislu monetarna politika HNB-ova držanja tečaja kune prema euru u minimalnim rasponima može smatrati sasvim opravdanim, jer bi u suprotnome posljedica bilo značajno destimuliranje izvoza. I iz ekonomskih teorije proizlazi da je za malu otvorenu zemlju poput Hrvatske najbolje rješenje odabir sustava fiksнog tečaja radi lakшeg prevladavanja egzogenih šokova (Babić, 2003). U kratkom roku pak veza tih dviju varijabli nije statistički značajna. Dokazi da je izvoz u tome model slabo egzogena varijabla pokazuju zapravo koliki utjecaj na same rezultate analize ima način modeliranja volatilnosti tečaja.

Na samom kraju treba napomenuti kako je ovim radom proučen samo mali dio utjecaja monetarne politike na realnu sferu gospodarstva. Holistički pristup istraživanju opravdanosti aktualne tečajne politike HNB-a zahtijevao bi mnogo širu perspektivu i obuhvatiti bi njezin utjecaj na kretanje vanjskog duga, opseg proizvodnje, kreditnu politiku komercijalnih banaka, ali i konvergenciju Hrvatske ka maastrichtskim ekonomskim standardima EU. U tom bi smislu bilo zanimljivo promotriti model kojim bi se analizirao način na koji kretanje tečaja utječe na sve navedene varijable, što u dugom, što u kratkom roku.

LITERATURA

- Agkiray, V., 1989.** "A new look at the Statistical Model Identification". *IEEE Transactions on Automatical Control*, (6), 716-723.
- Asteriou, D., 2006.** *Applied econometrics, A modern approach using E-views and Microfit*. New York: Palgrave Macmillan.
- Babić, M. i Babić, A., 2003.** *Međunarodna ekonomija*. Zagreb: Mate.
- Berra, A. K. and Higgins, M. L., 1993.** "ARCH models: properties, estimation and testing". *Journal of Economic Surveys*, 7 (4), 305-366.
- Brodsky, D. A., 1984.** "Fixed Versus Flexible Exchange Rates and the Measurement of Exchange Rate Instability". *Journal of International Economics*, 16 (3-4), 295-306.
- Cerovac, S., 2005.** "Novi kompozitni indikatori za hrvatsko gospodarstvo: prilog razvoju domaćeg sustava cikličkih indikatora". *Istraživanja*, br. 16. Zagreb: Hrvatska narodna banka.
- Chu, S. H. and Freud, S., 1996.** "Volatility Estimation for Stock Index Options: A GARCH approach". *Quarterly Review of Economics and Finance*, 36 (4), 431-450.
- Clark, P. B., 1973.** "Uncertainty, Exchange Risk, and the Level of International Trade". *Western Economic Journal*, 11 (September), 302-313.
- Cote, A., 1994.** "Exchange rate volatility and trade". *Bank of Canada Working Paper*, No. 5.
- Dell'Ariccia, G., 1999.** "Exchange Rate Fluctuations and Trade Flows: Evidence from the European Union". *IMF Staff Papers*, 46 (3), 315-334.
- Dickey, D. A. and Fuller, W. A., 1979.** "Distributions of the Estimators for Auto-regressive Time Series with Unit Root". *Journal of the American Statistical Association*, 74 (366), 427-431.

- Engle, R., 1980.** "Estimates of the Variance of US Inflation base on the ARCH model". *University of California, San Diego Discussion Paper*, 80-114.
- Engle, R., 1982.** "Autoregressive Conditional Heteroscedasticity with estimates of the Variance of United Kingdom Inflation". *Econometrica*, 50 (4), 987-1007.
- Erjavec, N., Cota, B. and Bahovec, V., 2004.** "The analysis of Croatian export functions: evidence based on exchange rate volatility". *Operational Research Proceedings KOI*, 213-222.
- Frankel, J. A. and Wei, S. J., 1993.** "Trade Blocs and Currency Blocks". *Working Paper*. No. 4335. Cambridge, Mass: National Bureau of Economic Research.
- Harris, R. I. D., 1995.** *Cointegration analysis in econometric modeling*. Harvester Wheatsheaf: Prentice Hall.
- HNB, 2007.** *Srednji devizni tečajevi Hrvatske narodne banke na kraju razdoblja* [online]. Dostupno na: [http://www.hnb.hr/publikac/bilten/statisticki_pregled/h10.xls?tsfs-g=98424af558a673d74fad1018ff34de0].
- Hooper, P. and Kohlhagen, S., 1978.** "The Effect of Exchange Rate Uncertainty on the Prices and Volume of International Trade". *Journal of International Economics*, (8), 4, 483-511.
- IMF, 1984.** "Exchange Rate Volatility and World Trade". *Occasional Paper*, No.28.
- Johansen, S., 1988.** "Statistical Analysis of Cointegration Vectors". *Journal of Economic Dynamics and Control*, 12 (2-3), 231-254.
- Jondeau, P., Roskinger, M. and Poon, S. H., 2006.** *Financial Modeling Under Non-Gaussian Distributions*. Lausanne: University of Lausanne.
- Kenen, P. and Rodrick, D., 1986.** "Measuring and analysing the effect of short term volatility in exchange rates". *Review of Economics and Statistics*, 68 (2), 311-319.
- Lumsdaine, R. L., 1996.** "Consistency and asymptotic normality of the quasi-maximum likelihood estimator in IGARCH(1,1) and covariance stationary GARCH(1,1) models". *Econometrica*, 64 (3), 575-596.
- McKenzie, M., 1999.** "The impact of Exchange rate Volatility on International Trade Flows". *Journal of Economic Surveys*, 13 (1), 71-106.
- Posedel, P., 2004.** *Svojstva i procjena GARCH modela*. Magistarski rad. Zagreb: Primorsko-dalmatinski fakultet.
- Posedel, P., 2006.** *Analiza tečaja i vrednovanja opcija na tečaj na hrvatskom tržištu: NGARCH model kao alternativa modelu Blacka i Scholesa*. Zagreb: Ekonomski fakultet.
- Rose, A. K., 2000.** "One Money, One Market: The Effect of Common Currencies on Trade". *Economic Policy*, (April), 9-45.
- Šošić, I., 2004.** *Primijenjena statistika*. Zagreb: Školska knjiga.
- Vizek, M., 2006.** "Econometric Analysis of Monetary Transmission Channels in Croatia". *Privredna kretanja i ekonomska politika*, br. 109.

Petar Sorić

The Impact of Kuna Exchange Rate Volatility on Croatian Exports

Abstract

The aim of this paper is to analyze the monetary transmission mechanism through the influence of exchange rate variability on export volume. To date it has been very common to use "historical volatility" as an approximation for exchange rate variability in empirical studies. However, many macroeconomic time series are characterized by heteroskedasticity, i.e. their variance is not constant over time. Thus in this paper the ARCH model is proposed as a model of conditional heteroskedasticity. Also, as an alternative to ARCH we will introduce historical volatility based not only on future but also on past exchange rate values. In exploring the influence of exchange rate volatility and domestic income on export volume, Johansen's multivariate cointegration approach and error-correction model (ECM) are used. The short run and long run relationships are analyzed separately. The results of econometric analysis draw attention to the different strengths of the relationship between kuna volatility and exports for the two proposed models. The first model shows a mild negative long-run relationship, while the second shows the much stronger aversion of Croatian exporters to volatility as a measure of exchange rate uncertainty.

Key words: ARCH model, Johansen's approach, ECM model, cointegration