

Željko Lovrinčević*
Maruška Vizek**

UDK 332.852.5(497.5)
JEL Classification P25, R31, R32
Izvorni znanstveni rad

DETERMINANTE CIJENA NEKRETNINA U REPUBLICI HRVATSKOJ I POTENCIJALNI UČINCI LIBERALIZACIJE TRŽIŠTA NEKRETNINA

U članku se analiziraju kretanja cijena nekretnina u odabranim zemljama članicama Europske Unije i u Hrvatskoj. Analizirano je razdoblje od godine 2000. do 2006., i pritom se ocjenjuje koliki je učinak na cijene nekretnina imalo pridruživanje novih zemalja članica Europskoj Uniji. Rezultati analize ukazuju na to da su nekretnine u Hrvatskoj i u Sloveniji u prosjeku skuplje od ostalih zemlja u tranziciji, a o utjecaju pridruživanja na kretanje cijena nekretnina ne može se donijeti jednoznačan zaključak. Zatim se provodi Johansen kointegracijska metoda i ocjenjuje se model korekcije odstupanja da bi se utvrdile kratkoročne i dugoročne determinante cijena nekretnina u Hrvatskoj. Pokazano je da je dohodovna elastičnost cijena nekretnina u dugome roku iznimno visoka i gotovo je tri puta veća od elastičnosti cijena nekretnina u odnosu na ponudu novih nekretnina. Cijene nekretnina u dugome roku reagiraju i na inflaciju i na promjene kamatnih stopa. U kratkome roku na cijene nekretnina najviše utječu krediti stanovništvu, dinamika sklapanja brakova i inflacija. Cijene nekretnina u Hrvatskoj mogle bi se povećati ako pridruživanje Europskoj Uniji dovede do povećanja raspoloživog dohotka stanovništva ili ako zbog pridruživanja ekonomski subjekti u Hrvatskoj formiraju pozitivna očekivanja o budućem dohotku.

Ključne riječi: determinante cijena nekretnina, model korekcije odstupanja, tranzicija

* Ž. Lovrinčević, dr. sc., viši znanstveni suradnik Ekonomski institut, Zagreb (zlovrincevic@eizg.hr)

** M. Vizek, dr. sc., znanstvena suradnica, Ekonomski institut, Zagreb (mvizek@eizg.hr)

1. Uvod

Tržište nekretnina u posljednjih se nekoliko godina učestalo nalazi u žarištu interesa hrvatske javnosti. Pojačano zanimanje javnosti posljedica je dinamičnoga povećanja cijena nekretnina što je ulagačima stvorilo priliku za ostvarivanje profita. Ubrzavanjem procesa pridruživanja Republike Hrvatske Europskoj Uniji događanja na tržištu nekretnina postala su ne samo tema medijskoga interesa, već i osjetljivo političko pitanje. Naime, Sporazumom o stabilizaciji i pridruživanju predviđeno je da Republika Hrvatska na početku godine 2009. u potpunosti liberalizira tržište nekretnina čime će se omogućiti da fizičke osobe koje su državljani zemalja članica EU-27 bez ograničenja kupuju hrvatske nekretnine.

No, veliko zanimanje javnosti za kretanja na tržištu nekretnina nije proporcionalno s brojem i učestalošću znanstvenih istraživanja o toj temi. Štoviše, u nedostatku kvalitetnih istraživanja u javnosti se često objavljuju veoma površne analize za koje se autori koriste podacima iz raznih neslužbenih i često veoma pristranih izvora. Analizira se isključivo hrvatsko tržište, čime se onemogućuje usporedba sa drugim zemljama i smještanje hrvatskoga tržišta nekretnina u globalni kontekst. Zbog primjene pristranih podataka i redukcionističkog pristupa, analize rezultiraju neispravnim sudovima o razlozima povećanje cijena nekretnina i iznose upitne procjene budućih kretanja na tržištu. Ne mora se posebno naglašavati da takve analize mogu biti veoma pogubne zato što utječu na formiranje očekivanja građana i poduzetnika o stanju i budućim trendovima na tržištu, a na osnovi očekivanja u konačnici se formiraju cijene nekretnina.

Cilj je ovoga rada smanjiti nedostatak kvalitetnih istraživanja i to tako da se analiziraju kretanja cijena nekretnina u Hrvatskoj i u zemljama članicama Europske Unije, koristeći se službenim podacima i primjerenim ekonometrijskim metodama. Na takav će se način moći donijeti zaključci o utjecaju koji bi pridruživanje Europskoj Uniji moglo imati na kretanje cijena nekretnina u Hrvatskoj. Rad se sastoji od pet cjelina. Nakon uvoda slijedi dio rada u kojem se analiziraju kretanja cijena nekretnina u novim i starim zemljama članicama te u Hrvatskoj. U trećem će dijelu rada biti govora o utjecaju pridruživanja Uniji novih zemalja članica i Španjolske na kretanja cijena nekretnina u tim zemljama. U četvrtome dijelu rada učinjena je empirijska analiza svrha koje je ustanoviti koje su determinante cijena nekretnina u kratkome i dugome roku. Nakon empirijskoga poglavlja slijedi zaključni dio rada u kojem su sažeti najvažniji rezultati obavljenih analiza.

2. Trendovi kretanja cijena nekretnina

Kretanja cijena nekretnina razmjerno je teško analitički pratiti, jer su za razliku od financijske imovine, kuće i stanovi izrazito heterogene kategorije s kojima se rijetko trguje, tržište je plitko i za nekretnine ne postoji jedno centralizirano tržište. Najprikladnija definicija vrijednosti nekretnine jest cijena koju nekretnina postiže na tržištu u danome trenutku. No budući da se u određenome trenutku trguje malim dijelom fonda nekretnina, a još se manjim dijelom trguje više puta, metodološki je osobito teško iz podataka o kupoprodajnim cijenama nekretnina izračunati prosječnu cijenu nekretnina i vrijednost ukupnog stambenog fonda. A zato što prikupljanje i analiza podataka o cijenama nekretnina zahtijeva velika sredstva, nije neočekivano da za većinu zemalja srednje i istočne Europe i baltičkih zemalja ne postoje pouzdane ocjene kretanja cijena nekretnina i ukupne vrijednosti stambenog fonda. Iako statistički uredi nekih zemalja u regiji prikupljaju podatke o cijenama nekretnina, metodologija prikupljanja podataka često nije objašnjena, a s prikupljenim je podacima teško obavljati međunarodne usporedbe, jer su metodologije prikupljanja podataka heterogene.

Valja stoga pripomenuti da na analizu koja je provedena u ovome dijelu rada, u kojoj se koristi prikupljenim podacima o kretanjima cijena nekretnina u zemljama srednje i istočne Europe i u baltičkim zemljama, valja gledati kao na okvirnu sliku trendova u regiji. Zaključke analize, zbog ograničene dostupnosti podataka i ponekad metodološke neusporedivosti podataka o cijenama, valja promatrati kao indikativne i usmjeravajuće za potrebe donošenja zaključaka o stanju hrvatskoga tržišta nekretnina.

2.1. Kretanja cijena nekretnina u novim zemljama članicama Europske Unije i u Hrvatskoj

Zbog ograničenja o kojima se raspravljalo u drugome poglavlju, prikupljeni su podaci o dinamici kretanja cijena nekretnina u zemljama srednje i istočne Europe i u baltičkoj regiji, tek djelomično usporedivi. Imajući na umu ograničenja međunarodne usporedbe cijena nekretnina, u tablici 1. dan je prikaz svih dostupnih podataka o cijenama nekretnina izraženih u eurima po metru kvadratnom za zemlje nove članice Europske Unije i za Hrvatsku i za njihove glavne gradove.

Tablica 1.

PROSJEČNA NOMINALNA CIJENA NEKRETNINA (EUR PO M²)

Obuhvat	Zemlja	1999.	2000.	2001.	2002.	2003.	2004.	2005.	2006.	Ukupno povećanje ** (u %)	Prosječno godišnje povećanje (u %)
Cijela zemlja	Slovačka	-	-	-	452*	633*	678*	632	-	40	13
	Češka	418	423	479	517	530	578	648	-	55	6
	Estonija	-	-	-	500	565	726	936	1135	127	23
	Letonija	-	-	-	-	-	221	267	-	21	21
	Mađarska	202	-	-	-	476	-	-	-	136	-
	Slovenija	-	-	-	-	-	-	-	-	-	-
	Poljska	-	376	413	374	322	256	345	-	-8	0
	Bugarska	-	162	164	166	186	277	378	420	159	19
	Hrvatska	-	-	1112	1130	1197	1316	1437	-	29	7
Glavni gradovi	Slovačka	-	-	-	552*	864*	1005*	851	-	54	19
	Češka	613	650	778	741	764	806	851	-	39	6
	Estonija	292	303	390	495	565	750	949	1476	405	27
	Letonija	332	515	520	590	318	341	478	-	44	12
	Mađarska	-	-	-	-	-	-	-	-	-	-
	Slovenija	1250	1300	1590	1630	1650	1800	2100	2300	84	9
	Poljska	-	-	-	-	-	629	916	-	46	46
	Bugarska	-	-	-	-	-	522	627	678	30	14
	Hrvatska	-	1243	1247	1255	1360	1393	1532	-	23	4,3

Izvor za originalne podatke: Statistički uredi Češke, Estonije, Latvije, Bugarske, Poljske i Hrvatske; Ministarstvo Republike Češke za regionalni razvitak; Palacin i Shelburne (2005.); Car (2006.); * - procjena autora; ** - prosječna prodajna cijena; odnosi se na promjenu cijena nekretnina za posljednji dostupni podatak u odnosu na prvi dostupni podatak.

Napomena: Podaci za 2006. odnose se na prvo polugodište 2006., a za Slovačku su podaci za 2005. dostupni samo za prvo polugodište; u cijenu nekretnina za Hrvatsku nisu uključeni POS stanovi.

Analizom tablice 1. može se uočiti da od godine 2000. postoji općeniti trend povećanja cijena. Sve su zemlje nove članice EU, osim Slovačke, u godinu 2005. nakon ulaska u EU zabilježile povećanje cijena nekretnina, i to u prosjeku od 25,7 % na nacionalnoj razini i 26,9 % u glavnim gradovima. Najdramatičnije povećanje veće od 40 % u godini 2005. u novim zemljama članicama EU zabilježeno je u glavnim gradovima Poljske i Letonije, a na nacionalnoj su razini cijene u godini ulaska u EU najsnažnije povećane u Estoniji i u Poljskoj (28,9 % i 34,7 %). Cijene nekretnina u glavnim gradovima u svim su slučajevima veće od cijena nekretnina u ostalim dijelovima država.

Ako uspoređujemo razine cijena nekretnina ili ako promatramo tržišta nekretnina iz perspektive EU-15 zainteresiranoga za kupnju nekretnina u regiji, najskuplje su nekretnine u Hrvatskoj,¹ a na razini glavnih gradova najskuplja je Ljubljana, poslije koje slijede Zagreb i Talin. Najjeftinije su nekretnine u Letoniji.

2.2. Kretanja cijena nekretnina u starim zemljama članicama Europske Unije

Budući da na cijene nekretnina utječu čimbenici koji su po svojoj naravi globalni (kao što su kretanja kamatnih stopa i poslovnih ciklusa), pa zato utječu na sve zemlje istodobno, ne iznenađuje da su u razvijenim zemljama cijene nekretnina usko korelirane. Važnost tih globalnih čimbenika varira od zemlje do zemlje, ali zato što oni objašnjavaju značajan dio varijacije cijena nekretnina, buduća će kretanja cijena nekretnina u srednjoj i istočnoj Europi i na Baltiku, biti pod utjecajem događanja na tržištu nekretnina u zapadnoj Europi. Stoga je, da bi se napravila procjena determinanti kretanja cijena nekretnina u RH, potrebno, osim na tržišta nekretnina zemalja u regiji, osvrnuti se i na tržišta nekretnina u zapadnoj Europi.

U većini zemalja EU-15 cijene nekretnina ponašaju se prema dugoročnom ciklusu koji se kreće oko pozitivnoga trenda. Dužina ciklusa većinom je oko 10 godina ili više, a amplitude kretanja cijena razmjerno su visoke (ECB, 2003.). Za vrijeme uzlaznoga trenda povećanja cijena nekretnina u kasnim osamdesetim i u ranim devedesetim godina 20. stoljeća, realne su cijene nekretnina povećane za oko 30 % od dola do vrha ciklusa, da bi nakon toga izgubile dio vrijednosti u nadolazećem silaznom dijelu ciklusa. No, u velikoj većini zemalja članica EU-15 i OECD, realne cijene nekretnina imaju izražen i ubrzan pozitivni trend od sredine devedesetih (posebno se ističu Irska, Nizozemska, Norveška, Velika Britanija i Španjolska) koji je zaustavljen na kraju godine 2007., kada je došlo do globalnoga zaokreta u kretanju cijena nekretnina.


Već sam pogled na sliku 1., dovoljno govori o intenzitetu rasta cijena nekretnina u EU-15, što je izazvalo intenzivne rasprave među ekonomistima i nositeljima ekonomskih politika o precijenjenosti tržišta nekretnina (odnosno da je došlo do pojave cjenovnog balona) i o tome bi li monetarna politika morala učiniti nešto

¹ Za Sloveniju ne postoje podaci na nacionalnoj razini, ali ako je suditi po cijenama nekretnina u Ljubljani, Slovenija bi, da podaci postoje, vjerovatno bila zemlja u regiji s nominalno najskupljim nekretninama u regiji.

da spriječi slom tržišta. Promatrajući iz današnje perspektive, možemo zaključiti da se na tržištima pojedinih zemalja članica EU-15 doista stvorio mjehur koji se rasprsnuo u tijeku 2008. i koji je u pojedinim zemljama izazvao usporavanje ekonomskoga rasta ili čak pad ekonomske aktivnosti.

Slika 1.

KRETANJE CIJENA NEKRETNINA U RAZVIJENIM ZEMLJAMA



Izvor: OECD (2004).

3. Utjecaj ulaska u Europsku Uniju na kretanja cijena nekretnina

Budući da se deset novih članica Europskoj Uniji pridružilo 1. svibnja 2004., zanimljivo je proučiti je li ulazak tih zemalja u EU utjecao na povećanje cijena nekretnina. Ako je suditi samo po podacima iz tablice 1. u kojoj su raspoloživi podaci za godine 2004. i 2005., nije moguće donijeti uniformni zaključak o kratkoročnom utjecaju ulaska u EU na kretanje cijena nekretnina u novim zemljama članicama. Naime, u nekim je zemljama u godinama 2004. i 2005. zabilježeno povećanje cijena nekretnina (Estonija, Latvija, Slovenija, Češka), a primjerice u Poljskoj u 2004. i u Slovačkoj u 2005. zabilježeno je sniženje cijena nekretnina.

Isto je tako teško dati zaključak o tome je li ulazak u EU utjecao na trend kretanja cijena u promatranim državama i zbog toga što se u promatranim ekonomijama, osim procesa pridruživanja Europskoj Uniji, odvijaju i neki drugi ekonomski procesi koji su zasigurno utjecali na kretanje cijena nekretnina. Pritom se ponajprije misli na pojavu kreditne ekspanzije u zemljama u regiji (i to pogotovo u onim zemljama koje imaju fiksni sustav tečaja), (vidi Boissay, Calvo i Kozluk, 2005.; Kiss, Nagy i Vonnak, 2005.) koja je praćena trendom snižavanja kamatnih stopa i visokim stopama povećanja nacionalnog dohotka. U takvim je uvjetima, ali i zbog nepostojanja pouzdanih i usporedivih dužih vremenskih serija cijena nekretnina u novim državama članicama EU, nemoguće nedvojbeno zaključiti kako će utjecati ulazak u EU na cijene nekretnina u novim zemljama članicama.

O utjecaju pridruživanja na cijene nekretnina u Grčkoj, u Španjolskoj i u Portugalu, koje su ušle u Uniju godine 1981. i godine 1986., ne možemo znati mnogo jer u to vrijeme uopće nisu vodile statistike o cijenama nekretnina. Podaci su praćeni samo za Španjolsku i prikazani su na slici 1. Sa slike je uočljivo da su cijene nekretnina u Španjolskoj u pet godina nakon ulaska u EU povećane za oko 100 %, nakon čega je uslijedila blaga korekcija cijena na niže koja je trajala do sredine devedesetih godina prošloga stoljeća.

Budući da obavljena analiza pokazuje da su, gledajući u usporedbi, nekretnine u Hrvatskoj skuplje u odnosu na većinu ostalih zemalja u regiji, u slijedećem će dijelu rada biti učinjena empirijska analiza koja bi morala dati odgovor na pitanje što određuje cijene nekretnina u Hrvatskoj? Kada se jednom dobije odgovor na to pitanje, a zato što nam u izvođenju ovoga zaključka ne pomažu iskustva zemalja u regiji koje su ušle u EU, moći će se s većom sigurnošću dati ocjena trenda kretanja cijena nekretnina poslije pridruživanja Hrvatske Europskoj Uniji.

4. Ekonometrijska analiza kretanja cijena nekretnina

U ovome će dijelu rada biti prikazana empirijska analiza kretanja cijena nekretnina u Hrvatskoj kojom će biti obuhvaćena većina čimbenika ponude i potražnje za nekretninama u namjeri da ispita koji od dotičnih čimbenika uvjetuju kretanje cijena nekretnina u Hrvatskoj u kratkome i dugome roku. Uz pomoć rezultata analize moći će se procijeniti mogući utjecaj ulaska u EU na kretanja cijena nekretnina. U tu svrhu će se u ovome dijelu rada koristiti kointegracijskom analizom i ravnotežnim modelom korekcije odstupanja (engl. error correction model; skraćeno ECM). Te su metode veoma zastupljene u literaturi koja se bavi objašnjavanjem povećanje cijena nekretnina. Tako se primjeri njezine uporabe mogu naći u Abelson, Joyeux i Milunovich (2005.), Annet (2005.), Hunt i Badia (2005.), Oikarinen (2005.) i Meen (2002.). Osim ECM u tu se svrhu koristi još i

modelima vektorske autoregresije i strukturne vektorske autoregresije (Tstsaronis i Zhu, 2004.; Sutton, 2002.) i raznim oblicima panel-modela (Nagahata et al., 2004; Terrones i Otrok, 2004.).

Za potrebe analize koristit će se sljedećim vremenskim nizovima tromjesečnih podataka:


- prosječna realna cijena kvadratnoga metra novosagrađenoga stana – bez POS stanova;
- realna kamatna stopa na dugoročne kredite s valutnom klauzulom stanovništvu;
- indeks obujma građevinskih radova;
- realna neto prosječna plaća po zaposlenome;
- indeks potrošačkih cijena;
- realan bruto domaći proizvod;
- realni ukupni krediti stanovništvu;
- jaz bruto domaćeg proizvoda i
- broj sklopljenih brakova.

Za vremenske nizove ukupni krediti stanovništvu i kamatna stopa na dugoročne kredite stanovništvu s valutnom klauzulom izvor je podataka Hrvatska narodna banka, a za sve je ostale nizove izvor podataka Državni zavod za statistiku. Analizira se razdoblje od početka godine 1995. do drugoga tromjesečja 2006. Svi su realni nizovi deflacionirani deflatorom potrošačkih cijena, osim realnoga BDP koji objavljuje Državni zavod za statistiku. U analizi su korištene logaritamske vrijednosti vremenskih nizova. Vremenski niz jaza BDP dobiven je oduzimanjem vrijednosti potencijalnoga BDP od stvarne realne vrijednosti BDP. Vrijednost potencijalnoga BDP dobivena je primjenom Hodrick – Prescott filtra s parametrom izgladivanja $\lambda=300$. Svi nizovi u razinama i prvim diferencijama prikazani su na slikama 2. i 3.

Pozornijim promatranjem slike 2. može se uočiti da sve serije, osim jaza BDP i prosječne cijene kvadratnoga metra stana, iskazuju trend kretanje. Također, ako je suditi po slici, jedino jaz BDP iskazuje sklonost vraćanja srednjoj vrijednosti, što bi ukazivalo da je navedeni niz stacionaran, a da su ostali nizovi nestacionarni u razinama. Na sljedećoj slici možemo ustanoviti da nizovi u prvim diferencijama: realna prosječna neto plaća, indeks obujma građevinskih radova, realni krediti stanovništvu i indeks potrošačkih cijena ne iskazuju sklonost vraćanju srednjoj vrijednosti, a to bi u konačnici značilo da su ti nizovi stacionarni u drugim diferencijama (tj. da imaju svojstvo integriranosti drugoga reda - $I(2)$), a da su ostali nizovi stacionarni u prvim diferencijama (tj. oni su $I(1)$).

Slika 2.

VREMENSKI NIZOVI U RAZINAMA




Izvor za originalne podatke: Hrvatska narodna banka i Državni zavod za statistiku.

Napomena: svi su vremenski nizovi logaritmirani; LPrh - prosječna realna cijena kvadratnoga metra novosagrađenog stana – bez POS stanova; LKta_sta - realna kamatna stopa na dugoročne kredite s valutnom klauzulom stanovništvu; LKr_sta - realni ukupni krediti stanovništvu; LBdp - realan bruto domaći proizvod – prilagođen za sezonu; LW - realna neto prosječna plaća po zaposlenome; LCPI - indeks potrošačkih cijena; LCon - indeks obujma građevinskih radova – prilagođen za sezonu; LBrak - broj sklopljenih brakova - prilagođen za sezonu; LBdp_jaz - jaz bruto domaćega proizvoda.

Ispitivanje reda integriranosti potrebno je zato što je za potrebe kointegracije prijeko potrebno da svi nizovi budu nestacionarni u razinama i da budu istoga reda integriranosti. To dalje znači da se u slučaju da je dio nizova I(1), a dio nizova I(2), od nizova koji su I(2) u testu kointegracije koristi njihovim prvim diferencijama (Hendry i Ericsson, 1992.). Da bismo provjerili zaključke o redu integriranosti nizova, zasnovane na grafičkoj analizi, učinjen je prošireni Dickey–Fullerov test jediničnih korijena koji se koristi metodom generalizirajućih najmanjih kvadrata (u daljem dijelu teksta ADF–GLS). Rezultati testova prikazani su u tablicama 2., 3. i 4.

Slika 3.

VREMENSKI NIZOVI U PRVIM DIFERENCIJAMA



Izvor za originalne podatke: Hrvatska narodna banka i Državni zavod za statistiku.

Tablica 2.

ADF-GLS TEST JEDINIČNIH KORIJENA – U RAZINAMA

Naziv varijable	Odabrani vremenski pomak	Test vrijednost	Kritična vrijednost 5 %	SBIC
LPrh	2	-1,939	-1,950	-4,726
LKta_sta	1	-1,216	-3,190	0,4912
LKr_sta	1	-1,805	-3,190	-7,0231
LBdp	1	-1,875	-3,190	-8,0285
LW	2	-0,669	-3,190	-7,7816
LCPI	1	-2,191	-3,190	-8,6814
LCon	1	-1,633	-3,190	-6,740
LBrak	3	-2,322	-3,190	-6,338
LBdp_jaz	1	-3,078*	-1,950	-8,2683

Izvor: izračun autora.

Napomena: uključeni trend i konstanta; sve su serije logaritmirane; * nulta hipoteza o postojanju jediničnog korijena odbačena na razini od 5 %.

Tablica 3.

ADF-GLS TEST JEDINIČNIH KORIJENA – U PRVIM DIFERENCIJAMA

Naziv varijable	Odabrani vremenski pomak	Test vrijednost	Kritična vrijednost 5 %	SBIC
LPrh	1	-5,064*	-1,950	-3,6808
LKta_sta	2	-5,789*	-3,190	-5,8314
LKr_sta	1	-2,444	-3,190	-7,0584
LBdp	1	-4,578*	-3,190	-7,9407
LW	5	-2,073	-3,190	-8,1099
LCPI	2	-2,517	-3,190	-8,5834
LCon	1	-3,018	-3,190	-6,7645
LBrak	1	-5,387	-3,190	-6,065

Izvor: izračun autora.

Napomena: uključeni trend i konstanta; sve su serije logaritmirane; * nulta hipoteza o postojanju jediničnog korijena odbačena na razini od 5 %.

Tablica 4.

ADF-GLS TEST JEDINIČNIH KORIJENA – U DRUGIM DIFERENCIJAMA

Naziv varijable	Odabrani vremenski pomak	Test vrijednost	Kritična vrijednost 5 %	SBIC
LKr_sta	2	-7,021*	-3,190	-5,2971
LW	1	-5,756*	-3,190	-7,5662
LCPI	2	-2,517	-1,950	-8,4228
LCon	1	-2,592	-1,950	-6,2374

Izvor: izračun autora.

Napomena: uključeni trend i konstanta; sve su serije logaritmirane; * nulta hipoteza o postojanju jediničnog korijena odbačena na razini od 5 %.

Pažljivijim proučavanjem tablica 2., 3. i 4. može se utvrditi da je jaz BDP stacionaran vremenski niz. Nizovi prosječna cijena metra kvadratnoga novosagrađenoga stana, BDP, kamatna stopa na kredite stanovništvu i broj sklopljenih brakova jesu $I(1)$, a indeks građevinskih radova, neto plaća i indeks potrošačkih cijena jesu $I(2)$. Pošto je ustanovljen red integriranosti vremenskih nizova, može se započeti s kointegracijskom analizom. Koristit će se Johansen kointegracijskom metodom s ocjenom uz pomoć metode najveće vjerojatnosti (Johansen, 1988.; Johansen, 1991.).

U testiranje kointegracijskoga odnosa uključit će se slijedeći vremenski nizovi;²

- prosječna realna cijena kvadratnoga metra novosagrađenoga stana;
- realna kamatna stopa na dugoročne kredite s valutnom klauzulom stanovništvu;
- prva diferencija indeksa obujma građevinskih radova;
- prva diferencija realne neto prosječne plaća po zaposlenome i
- prva diferencija indeksa potrošačkih cijena.

Indeks građevinskih radova čimbenik je ponude nekretnina, a realna je neto plaća čimbenik potražnje za nekretninama. Kamatna stopa na kredite stanovništvu predstavlja i čimbenik potražnje za nekretninama, ali neposredno i karakter monetarne politike u zemlji. Inflacija je uključena u kointegracijski vektor, jer je u literaturi ustanovljeno da je inflacija značajna za kretanje cijena nekretnina u dugome roku zato što je ulaganje u nekretnine svojevrsna zaštita od inflacije (Abelson, Joyeux i Milunovich, 2005.).

Rezultati Johansenove metode i ograničenja na ustanovljeni kointegracijski prostor prikazani su u tablicama 5. i 6. Iz prve se tablice vidi da na razini signifikantnosti od 5 % postoji 1 kointegracijski vektor; tj. jedan dugoročan ravnotežni odnos među odabranim vremenskim nizovima. U slijedećoj tablici prikazani su parametri kointegracijskoga vektora i parametri prilagodbe bez ograničenja i s ograničenjima. U kointegracijskom vektoru bez ograničenja uočljivo je da su svi vremenski nizovi teorijski ispravnoga predznaka.³ Tako se na rast kamatne stope od 1 % u dugome roku cijene nekretnina smanjuju za 0,28 %, a rast obujma građevinskih radova od 1 % smanjuje cijenu nekretnina za 1,75 %.

Dohodovna elastičnost cijena nekretnina u dugome roku posebno je visoka i iznosi 6.28 %, što je gotovo tri puta više od elastičnosti cijena nekretnina na promjenu u ponudi na tržištu nekretnina. Isto je tako, kao što se i moglo očekivati, povećanje opće razine cijena, pozitivno povezano u dugome roku s rastom cijena

² Ostalim će se vremenskim nizovima koristiti za ocjenu ECM modela.

³ Implicitno jedno ograničenje ipak postoji, a to je normalizacija po varijabli Prh koja je prijeko potrebna jer Johansenova metoda ne daje jedinstveno rješenje.

nekretnina, a to bi moglo značiti da se ulaganjem u nekretnine štiti od inflacije. Parametri prilagodbe za sve nizove, osim cijena nekretnina, osobito su izuzetno niski, što bi značilo da se u kratkome roku na promjene prilagođuje isključivo cijena nekretnina.

Tablica 5.

REZULTATI JOHANSENOVE KOINTEGRACIJSKE METODE

Vlastita vrijednost	Rang	trace statistika	p-vrijednost
-	0	74,303*	[0,019]
0.53436	1	44,493	[0,099]
0.48568	2	18,562	[0,535]
0.22451	3	8,6460	[0,406]
0.13762	4	2,8719	[0,090]
0.070992	5	-	-

Izvor: izračun autora.

Napomena: Uključena 3 vremenska pomaka;; vremenski pomak utvrđen SBIC-om; * - hipoteza odbačena na razini signifikantnosti od 5 %.

Tablica 6.

OGRANIČENJA NA KOINTEGRACIJSKI PROSTOR I PRIPADAJUĆI PARAMETRI

Ograničenja na kointegracijski prostor	Bez ograničenja		Slaba egzogenost	
	Parametri kointegracijskoga vektora	Parametar prilagodbe	Parametri kointegracijskoga vektora	Parametar prilagodbe
Vremenski nizovi				
LPrh	1	-0,82291	1	1
LKta_sta	0,28376	0,13894	0,23912	0
LW	-6,2821	0,066560	-5,3497	0
LCPI	-0,43598	-0,017518	-0,80541	0
LCon	1,7543	0,063732	1,6881	0

Izvor: izračun autora.

Budući da je slijedeći korak analize prijelaz na jednu jednadžbu s uključenim ECM kojom će se modelirati kretanje cijena nekretnina u kratkome roku, prijeko je potrebno kointegracijski prostor ograničiti tako da svi parametri prilagodbe, osim onoga uz cijene nekretnina budu jednaki 0 (drugi stupac tablice). To je ograničenje prihvaćeno (LR test, $\text{Chi}^2 = 3.20 [0.67]$), čime je utvrđena slaba egzogenost kamatne stope na ukupne kredite, na indeks potrošačkih cijena, na neto plaću i građevinske aktivnosti u odnosu na cijene nekretnina. Stoga će se ECM niz za potrebe neograničenoga modela konstruirati parametrima kointegracijskoga vektora iz tablice 6. dobivenih nakon uvođenja ograničenja.

Kratkoročan model, tj. opći neograničeni model kojim se objašnjava kretanja cijena nekretnina, konstruiran je isključivo sa stacionarnim varijablama. To znači da su cijena nekretnina, BDP, kamatna stopa i broj sklopljenih brakova u modelu u prvim diferencijama, BDP jaz u razinama, a krediti stanovništvu, neto plaća, indeks potrošačkih cijena i indeks građevinskih radova u drugim diferencijama.⁴ U modelu su uključena po tri vremenska pomaka za svaku objašnjavajuću varijablu i jedan vremenski pomak za ECM niz.

Nakon ocjene općega ograničenoga modela slijedi proces reduciranja modela koji se obavlja Waldovim testom isključenja i transformacijom varijabli koje imaju isti predznak. Iz modela se također mogu isključiti i nizovi koji imaju nelogičan predznak, a u modelu se mogu zadržati nizovi koji nisu statistički značajni, ali su važni zbog ekonomske teorije koja se veže uz kretanje cijena nekretnina. Isto se tako, provodi i LaGrangeov test multiplikatora kojim se testira nedostaje li neka važna varijabla u modelu. Tim se procesom opći neograničeni model sa 26 varijabli opisanih u prethodnome poglavlju 3 smanjio na manji model sa 8 varijabli koji glasi:⁵

$$\begin{aligned} \text{Prh} = & 5 + 0,5\text{Kr_sta}_{-4} + 0,4\text{Brak}_{-2} - 0,07\text{Con}_{-3} \\ & (0.01) \quad (0.01) \quad (0.75) \\ & + 0,9\text{Cpi}_{-3} - 0,6\text{Bdp_jaz}_{-1} - 0,8\text{W}_{-1} - 0,6\text{ECM}_{-1} \\ & (0.1) \quad (0.34) \quad (0.07) \quad (0.00) \end{aligned}$$

Iz modela se vidi da u kratkome roku na povećanje cijena nekretnina djeluje povećanje kredita stanovništvu (s pomakom od 4 tromjesečja), povećanje broja sklopljenih brakova (s pomakom od 2 tromjesečja) i povećanje opće razine cijena (s pomakom od 3 tromjesečja). ECM varijabla statistički je značajna i odgovarajućeg je predznaka. Koeficijent uz ECM sugerira da je proces prilagodbe

⁴ Sa druge strane, ECM niz da bi postojao mora biti stacionaran.

⁵ U zagradama su prikazane p-vrijednosti.

razmjerno brz, odnosno da se 60 % prilagodbe obavlja u jednom tromjesečju. U modelu su još zadržani BDP jaz i obujam građevinskih radova, koji nisu statistički značajni i varijabla realnih bruto plaća koja je statistički značajna, ali ima negativan predznak.

Model prolazi sve dijagnostičke testove (vidi tablicu 7.), a Chowovi testovi ne pokazuju postojanje strukturnih prekida u modelu.

Tablica 7.

PREGLED DIJAGNOSTIČKIH TESTOVA

Naziv testa	Test	Test - vrijednost	p-vrijednost
AR 1-3	F(3,26)	2,1375	0,1198
ARCH 1-3	F(3,23)	0,29583	0,8280
Normalnost reziduala	Chi ² (2)	3,1004	0,2122
Heteroskedastičnost reziduala	F(13,15)	0,20756	0,9965
RESET	F(1,28)	1,3553	0,2542

Izvor: izračun autora.

Ono što se ovom analizom može pokazati o tome kakav je utjecaj ulaska Hrvatske u Europsku Uniju na kretanje cijena nekretnina jest da će se cijene nekretnina povećati ponajprije zbog povećanja životnog standarda građana Hrvatske. To znači, ako se zbog ulaska u EU realna neto plaća trajno poveća za 1 % može se očekivati da će rast cijena nekretnina biti nešto više od 5 %. Postoji i mogućnost da će se povećanje cijena nekretnina povećati nakon ulaska u EU, ako ulazak u EU donese dalje snižavanje kamatnih stopa na stambene kredite. No, upitno je koliko je ta mogućnost vjerojatna, jer je dugoročan trend izrazito niskih realnih kamatnih stopa u Europi završen. Onoga trena kada dođe do povećavanja kamatnih stopa na europskome tržištu novca, kredita i depozita i kada se ta promjena prenese na hrvatsko tržište (a takva je mogućnost značajna zato što su hrvatske banke u vlasništvu banaka s područja EU-15), smanjivat će se cijene nekretnina. Nažalost, ne možemo ništa reći o utjecaju povećane strane potražnje za nekretninama na cijene nekretnina u Hrvatskoj, jer u model nismo uključili vremenski niz kojim bismo aproksimirali stranu potražnju.

4. Zaključak

Rezultati Johansenove metode ukazuju na to da je dohodovna elastičnost cijena nekretnina u dugome roku osobito velika (6.28 %) i gotovo je tri puta veća od elastičnosti cijena nekretnina na promjenu u ponudi na tržištu nekretnina. Naime, povećanje obujma građevinskih radova od 1 % smanjuje u dugome roku cijenu nekretnina tek za 1,75 %. Dalje, ako se kamatne stope povećaju 1 % u dugome roku, cijene nekretnina se smanjuju za 0,28 %. Cijene nekretnina u dugome roku reagiraju i na inflaciju, tj. povećanje opće razine cijena pozitivno je povezano s povećanjem cijena nekretnina, pa ulaganje u nekretnine služi kao zaštita od inflacije. U kratkome roku na cijene nekretnina najviše utječu krediti stanovništvu, broj sklopljenih brakova i inflacija. Na osnovi dobivenih rezultata dugoročnoga modela možemo zaključiti da će pridruživanje Europskoj Uniji izazvati povećanje cijena nekretnina u Hrvatskoj povećanjem dohotka, a to znači da bi se cijene nekretnina mogle povećati ako pridruživanje dovede do povećanja raspoloživog dohotka stanovništava ili ako zbog pridruživanja ekonomski subjekti formiraju pozitivna očekivanja o budućem dohotku. No Hrvatska će se, prije nego što se pridruži Europskoj Uniji zbog posljedica globalne financijske krize morati suočiti sa značajnim usporavanjem realnoga ekonomskoga rasta i sa znatno nepovoljnijim uvjetima odobravanja novih kredita. Zbog visoke dohodovne elastičnosti cijena nekretnina može se očekivati da će takav razvitak događaja dovesti do sniženja cijena nekretnina u Hrvatskoj. U tome bi kontekstu potpuna liberalizacija tržišta nekretnina za strance u veljači godine 2009. djelovala tako da se smanjuju očekivane korekcije cijena prema dolje.

REFERENCE

- Abelson, P., Joyeux, R., Milunovich, G. i Chung, D. (2005.). «Explaining house prices in Australia: 1970-2003», *Economic Record*, (81): 96-103.
- Annett, A. (2005.). «Euro area policies: Selected issues», *IMF Country Report*, br. 05/266.
- Boissay, F. Calvo, O. i Kozluk, T. (2005). «Is Lending in Central and Eastern Europe developing too fast?», rad sa Konferencije o Europskoj ekonomskoj integraciji, Središnja banka Austrije, Beč.
- Car, M. (2006.). «Monitoring Residential Property Prices in Slovakia», Slovačka središnja banka.
- ECB (2003.). «Structural factors in the EU housing markets», European Central Bank.

- Hendry, D. i Ericsson, N. (1992.). «Modelling the Demand for Narrow Money in UK and USA», *European Economic Review*, (35), 4: 833-881.
- Johansen, S. (1988.). «Statistical Analysis of Cointegration Vectors», *Journal of Economic Dynamics and Control*, (12): 231-254.
- Johansen, S. (1991.). «Estimation and Hypothesis Testing of Cointegration Vectors in Gaussian Vector Autoregression», *Econometrica*, (59), 6: 1551-1580.
- Kiss, G., Nagy, M. i Vonnak, B. (2006.). «Credit Growth in CEE: Trend, Cycle or a Boom?», članak prikazan na konferenciji «Banking Supervision Committee 36th meeting», 13. lipanj 2006., Rim.
- Meen, G. (2002.). «The time-series behaviour of house prices: A transatlantic divide», *Journal of Housing Economics*, (11), 1: 1-23.
- Nagahata, T., Saita, Y., Sekine, T. i Tachibana, T. (2004.). «Equilibrium land prices of Japanese prefectures: A panel cointegration analysis», *Bank of Japan Working Paper Series*, Br. 04-E-9.
- OECD (2004.). *Economic Outlook*, br. 78.
- Oikarinen, E. (2005.). «Is housing overvalued in the Helsinki Metropolitan Area?», *Keskusteluiheita Discussion papers*, br. 992, The Research Institute of the Finnish Economy.
- Palacin, Jose i Shelburne, R. C. (2005.). «The private housing market in Eastern Europe and the CIS», *Discussion paper* br. 6, United Nations Economic Commission for Europe.
- Sutton, G. (2002.). «Explaining changes in house prices», *BIS Quarterly Review*, Bank for International Settlements, September.
- Terrones, M. i Otrok, C. (2004.). «The global house price boom», *IMF World Economic Outlook*, September.
- Tstsaronis, K. i Zhu, H. (2004.). «What drives housing price dynamics: Cross country evidence», *BIS Quarterly Review*, Bank for International Settlements, March.

HOUSE PRICE DETERMINANTS IN THE REPUBLIC OF CROATIA AND
POTENTIAL EFFECTS OF HOUSING MARKET LIBERALIZATION

Summary

The paper analyses house price developments during 2000-2006 period in the selected EU member states and Croatia. The analysis assesses the effect of EU joining on house prices in new member states. The results indicate that housing in Croatia and Slovenia is on average more expansive when compared with the rest of the new member states, while the effect of joining on house prices is ambiguous. Johansen cointegration method and error correction method is estimated in order to determine long- and short-run elasticities of house prices in Croatia. The results suggest that long-run income elasticity of house prices is quite high – three times higher than the supply side elasticity. In the long run house prices also respond to changes in inflation and interest rates. In the short run credits to households, demographic developments and inflation affect house prices the most. If Croatian joining the Union causes higher disposable income or positive expectations of future income, house prices in Croatia might rise as a consequence.

Key words: house price determinants, error correction model, transition.