

Istraživanja I-63

Dome, slatki dome: učinak subvencioniranja stambenih kredita na tržište nekretnina u Hrvatskoj

Davor Kunovac, Ivan Žilić

Zagreb, srpanj 2021.



Navodi u tekstu stavovi su autora te ne moraju nužno izražavati
stajalište ili mišljenje Hrvatske narodne banke.

Home sweet home: The effects of housing loan subsidies on the housing market in Croatia*

Abstract

In this paper, we explore whether a program of housing loan subsidies introduced in Croatia contributed to housing price increases. The subsidy was designed to cover a portion of annuities in the initial period of the housing loan repayment, with a distinct feature that a household could apply for the subsidy only during a monthlong period. Using a dataset on housing transactions we document that the subsidy disrupted the usual intra-annual dynamics of residential transactions as they became very concentrated in the month when housing loan subsidy applications ended. Using an event study approach we find that the housing prices increased just around the introduction of the subsidy. In order to discuss possible confounders, we exploit the subsidy built-in implementation rules, discuss the role of the international housing cycle, and explore the interplay of the housing market and tourism in Croatia. We conclude that the housing loan subsidy acted as a procyclical policy that contributed to the already increasing trend of housing prices. Finally, exploiting the regional variation in the subsidy intensity, we conclude that housing price capitalization was driven by prices in areas and regions with already active housing markets.

Keywords: housing loan subsidy, price capitalization, hedonic regressions, evaluation.

JEL: H24, R21, R31.

* Davor Kunovac (davor.kunovac@hnb.hr) is the director of the Modeling Department at the Croatian National Bank. Ivan Žilić (izilic@eizg.hr) is a research associate at the Institute of Economics, Zagreb, and a research associate at the London School of Economics Research on South Eastern Europe. This paper is a result of Žilić's research stay in the Modeling Department of the Croatian National Bank. The views and conclusions expressed in this paper are those of the authors and do not necessarily reflect the position of institutions that the authors work for. We thank Karlo Kotarac for his help with the dataset on housing transactions, the anonymous referee on useful suggestions, and participants of the 34th Croatian National Bank Economic Workshop. All remaining errors are our own.

Sažetak

U radu istražujemo je li subvencioniranje stambenih kredita pridonijelo povećanju cijena nekretnina u Hrvatskoj. Subvencija, uvedena 2017. godine, provodi se pokrivanjem dijela anuiteta tijekom početnog razdoblja otplate stambenoga kredita, sa specifičnim ograničenjem da se kućanstvo može prijaviti za subvenciju samo tijekom kratkog razdoblja. Na temelju analize podataka o svim stambenim transakcijama od 2015. do kraja 2019. godine dokumentiramo da je uvođenje subvencije poremetilo uobičajenu mjesečnu dinamiku stambenih transakcija koje su postale vrlo koncentrirane u mjesecu u kojem su se predavali zahtjevi za subvencioniranje. Primjenjujući metodu *analize događaja* (engl. *event study*), nalazimo da su se cijene stanova povećale upravo u razdoblju oko uvođenja subvencije. Kako bismo potvrdili zaključke naše osnovne specifikacije, provodimo i niz dodatnih analiza: koristimo se pravilima subvencioniranja stambenih kredita u svrhu osiguravanja dodatnih kontrolnih skupina, razmatramo ulogu međunarodnog ciklusa cijena nekretnina te istražujemo povezanost tržišta nekretnina i turizma u Hrvatskoj. Zaključujemo da je subvencioniranje stambenih kredita djelovalo kao prociklična mjera koja je pridonijela postojećem trendu rasta cijena stanova u Hrvatskoj. Konačno, na osnovi regionalnih varijacija u intenzitetu subvencija koje su uvedene 2018. godine, zaključujemo da su subvencije utjecale na cijene nekretnina u područjima i regijama u kojima je tržište nekretnina najaktivnije.

Ključne riječi: subvencioniranje stambenih kredita, tržišna kapitalizacija, hedonistička regresija, evaluacija mjera

JEL klasifikacija: H24, R21, R31

* Davor Kunovac (davor.kunovac@hnb.hr) direktor je Direkcije za modeliranje Hrvatske narodne banke. Ivan Žilić (izilic@eizg.hr) znanstveni je suradnik Ekonomskog instituta, Zagreb i znanstveni suradnik na London School of Economics Research on South Eastern Europe. Ovaj je rad rezultat istraživačkog boravka Ivana Žilića u Direkciji za modeliranje Hrvatske narodne banke. Za stajališta i zaključke iznesene u ovom radu odgovorni su autori i ta stajališta i zaključci nisu nužno istovjetni službenim stajalištima institucija za koje autori rade. Zahvaljujemo Karlu Kotarcu na pomoći u vezi sa skupinom podataka o stambenim transakcijama, anonimnom recenzentu na korisnim sugestijama i sudionicima 34. ekonomske radionice Hrvatske narodne banke. Autori snose odgovornost za sve preostale pogreške.

Sadržaj

Abstract.....	3
Sažetak.....	4
Sadržaj	5
1. Uvod.....	6
2. Institucionalno okruženje i subvencioniranje stambenih kredita.....	9
3. Podaci i empirijski pristup	13
3.1. Analiza studije događaja.....	15
3.2. Međunarodne cijene stambenih nekretnina	22
3.3. Turistička aktivnost i cijene stambenih nekretnina u Hrvatskoj.....	24
3.4. Analiza geografskog diskontinuiteta intenziteta subvencioniranja stambenih kredita.....	29
4. Zaključci.....	33
5. Literatura.....	34
6. Dodatak	37

1. Uvod

Pristupačnost stanovanja redovito se nalazi visoko na listi prioriteta kreatora javnih politika. Životni prostor („zaklon“ ili „sklonište“) temeljna je ljudska potreba i za većinu je kućanstava kupnja stambene nekretnine najvažnija financijska odluka, koja se često financira zaduživanjem. Kućanstva obično žele kupiti stambenu nekretninu zbog nekoliko glavnih razloga: od ekonomskih i financijskih preko društveno-demografskih do psiholoških i biheviorističkih (Hu, 2013.). Uz navedeno, visoke stope stambenog vlasništva (engl. *homeownership rate*) imaju mnogo pozitivnih aspekata. Tako se na primjer one povezuju s nižim stopama kriminala (Dietz i Haurin, 2003.), boljim ishodima djece (Haurin *et al.*, 2002.) i većim odazivom na glasovanje (DiPasquale i Glaeser, 1999.). No, s druge strane, vlasništvo nad nekretninama povezuje se i s mnogim troškovima. Apgar (2004.) i Lubell (2014.) analiziraju one glavne, uključujući preuzimanje dugoročne obveze na život u određenom objektu (građevini), ulaganje u nediversificiranu imovinu kojoj može pasti vrijednost i manju mobilnost rada (Caldera i Andrews, 2011.).

Uzimajući u obzir i pozitivne i negativne aspekte stambenog vlasništva, čini se kako su mnoge zemlje i nadalje voljne izravno intervenirati na tržištu stambenih nekretnina. To uglavnom čine uz pomoć fiskalnih mjera u obliku subvencija i poreza, izravnim osiguravanjem socijalnog stanovanja i doplatcima za stanovanje te propisima (Andrews i Sánchez, 2011.; Andrews *et al.*, 2011.). Pitanje je povećavaju li takve mjere uopće udio nekretnina u vlasništvu. Na primjer, provedena istraživanja analiziraju potencijalnu korist koju kupci stambenih nekretnina u SAD-u imaju od poreznih odbitaka za kamate na stambene kredite (Hilber i Turner, 2014.; Rappoport, 2016.; Sommer i Sullivan, 2018.). U tom konkretnom slučaju konačan utjecaj državne intervencije na stopu stambenog vlasništva ostaje nejasan jer agregatne cijene nekretnina zbog ovakve intervencije rastu. Povećana nepristupačnost nekretnina u konačnici može utjecati na preferencije kućanstava u odnosu na kupovinu i najam nekretnina. Mehanizam porasta cijena nekretnina ovdje je u biti jednostavan, kao što to pokazuju Hilber i Turner (2014.). Ako je ponuda nekretnina neelastična, umjesto da potiču vlasništvo, porezni odbici za kamate na stambene kredite mogu se reflektirati u višim cijenama nekretnina.

U skladu sa spomenutom srodnom literaturom u ovom radu analiziramo je li program subvencioniranja stambenih kredita u Hrvatskoj potaknuo ukupan rast cijena stambenih nekretnina. Hrvatska je pritom zanimljiva za analizu politika koje potiču stambeno vlasništvo zbog tri razloga. Prvo, u Hrvatskoj se posljednjih godina bilježi vrlo snažan rast cijena nekretnina (Slika 1.). Drugo, za Hrvatsku je karakteristična iznimno visoka stopa stambenog vlasništva, primjerice, u 2018. ona je iznosila približno 90%. Hrvatska je tako, zajedno sa Slovačkom i Rumunjskom, među svim državama EU-a imala najvišu stopu stambenog vlasništva (Eurostat, 2020.a). Premda tako visoku stopu stambenog vlasništva određuje mnogo čimbenika, Kreitmeyer (2009.) navodi da se hrvatska kućanstva naprosto bolje osjećaju kada žive u vlastitim stambenim nekretninama koje

smatraju stabilnijim rješenjem, dok se najam često smatra nesigurnim i privremenim. Posljednja je važna značajka tržišta nekretnina u Hrvatskoj njegova povezanost s intenzitetom turističke djelatnosti u Hrvatskoj, koja u 2018. bilježi više od 89 milijuna noćenja (Eurostat, 2020.b). Nadalje, hrvatski se turizam u velikoj mjeri oslanja na privatni smještaj, što stvara pritisak na ponudu stambenih nekretnina. Primjerice, od ukupnog broja kreveta u Hrvatskoj u 2018. godini 61,3% odnosilo se na krevete izvan hotelskih kapaciteta i onih u kampovima, po čemu je Hrvatska bila druga u EU-u (Eurostat, 2020.c).

Slika 1. Indeks cijena stambenih nekretnina u Hrvatskoj



Izvori: Hrvatska narodna banka; Državni zavod za statistiku

Program subvencioniranja stambenih kredita koji je predmet naše analize uveden je 2017. radi olakšavanja kupnje stambenih nekretnina i proveden je tako da subvencije pokrivaju dio anuiteta u početnom razdoblju otplate stambenoga kredita. Iako se provedba subvencija mijenjala tijekom godina, prema inačici subvencije iz 2017. država pokriva 50% mjesečnih anuiteta u prve četiri godine kredita, pri čemu se to razdoblje može produljiti ako kućanstvo dobije dijete tijekom trajanja subvencije. Specifičnost je ovog programa da kućanstvo može podnijeti zahtjev za subvenciju samo unutar razdoblja od mjesec dana, obično u rujnu i listopadu. Budući da subvencioniranje stambenih kredita osigurava očiglednu financijsku injekciju kućanstvima, ono ubrzo postaje vrlo popularno te su subvencionirani krediti po uvođenju programa subvencioniranja činili oko 10% svih stambenih transakcija u Hrvatskoj. To posebno vrijedi u područjima koja su već i otprije imala aktivna tržišta nekretnina.

Koristeći se mikropodacima Porezne uprave Ministarstva financija o svim stambenim transakcijama u Hrvatskoj od 2015. do 2019., analiziramo utjecaj subvencioniranja stambenih kredita na dinamiku i cijene na tržištu stambenih nekretnina. Imajući na umu da potencijalni učinci prelijevanja programa subvencioniranja mogu utjecati na sve nekretnine koje se nalaze na tržištu, fokus naše analize nije isključivo na

subvencioniranim stambenim transakcijama, već na tržištu svih stambenih nekretnina u Hrvatskoj. Najprije pokazujemo da su subvencije znatno poremetile uobičajenu unutargodišnju (mjesečnu) dinamiku trgovanja stambenim nekretninama koje je sada vrlo koncentrirano u listopadu, mjesecu u kojem istječe rok za podnošenje zahtjeva za subvencioniranje kredita. To pokazuje da su subvencije stvorile usko grlo na tržištu koje može dovesti do poremećaja u pregovorima o cijenama i, općenito, u procesu potrage za stambenim nekretninama s obzirom na to da se stambene transakcije trebaju okončati unutar kratkog razdoblja. Primjenjujući pristup studije događaja, ovdje uveden hedonističkom regresijom, uočavamo da su cijene stambenih nekretnina trajno porasle upravo u razdoblju neposredno nakon uvođenja državnih subvencija. Konačno, koristeći se pravilima o provedbi subvencija stambenih kredita (maksimalni ukupni iznos, jedinična cijena za koju se može dobiti subvencija) i unaprijed određenih značajki nekretnine (veličina koja određuje ukupnu cijenu i godina izgradnje koja određuje jediničnu cijenu) definiramo i dodatne kontrolne skupine transakcija nekretninama kako bismo potvrdili naše osnovne zaključke o utjecaju programa subvencioniranja na cijene nekretnina u Hrvatskoj.

Kako bismo procijenili je li opaženo povećanje cijena izravna posljedica subvencija ili eventualnih drugih odrednica cijena stambenih nekretnina, provodimo i dvije dodatne analize. Točnije, analiziramo utjecaj koji međunarodni ciklusi cijena nekretnina i potražnja za turističkim uslugama mogu imati na cijene stambenih nekretnina u Hrvatskoj.

Iako kupnja stambene nekretnine (“nerazmjenjivog dobra”) u inozemstvu općenito nije dobar supstitut za kupnju nekretnine u Hrvatskoj, cijene nekretnina mogu imati snažnu zajedničku međunarodnu komponentu. Kako bismo ispitali je li uočeno povećanje cijena stambenih nekretnina u Hrvatskoj dio širih međunarodnih kretanja, analiziramo zajedničku komponentu cijena stambenih nekretnina u zemljama EU-a i procjenjujemo njezinu važnost za cijene stambenih nekretnina u Hrvatskoj. Iako postoji povezanost između ove zajedničke komponente i cijena stambenih nekretnina u Hrvatskoj, recentno povećanje cijena stambenih nekretnina u Hrvatskoj ne može se u potpunosti objasniti zajedničkim ciklusom cijena stambenih nekretnina. Stoga su naši rezultati u skladu sa stajalištem prema kojem je međunarodni financijski ciklus važna odrednica cijena stambenih nekretnina u Hrvatskoj od 2017., no domaće su cijene također pod značajnim utjecajem idiosinkratske domaće komponente čija dinamika koincidira s uvođenjem programa subvencioniranja. Zaključujemo stoga da je subvencioniranje stambenih kredita djelovalo kao prociklična mjera, koja je pridonijela postojećem trendu rasta cijena stanova u Hrvatskoj, no nije bila dominantna odrednica kretanja cijena proteklih godina.

Nadalje, ispituje se proizlazi li opaženi porast cijena nakon listopada 2017., koji povezujemo s uvođenjem subvencija stambenih kredita, iz porasta turističke aktivnosti, koja trajno stvara pritisak na ponudu stambenih nekretnina. U svrhu detaljnije analize u specifikaciju hedonističke regresije uključujemo i turističke pokazatelje te dodatno ispituje se upućuju li ostali pokazatelji u turizmu i stanovanju (udio stambenih

nekretnina koje su kupili stranci i stambene transakcije unutar regija u Hrvatskoj) na diskontinuitet u vrijeme uvođenja subvencija stambenih kredita. Rezultati te dodatne analize potvrđuju naše osnovne zaključke: cijene nekretnina rastu s uvođenjem subvencija i nakon uključivanja pokazatelja turizma u ekonometrijsku specifikaciju. Ipak, to ne znači da je turizam u potpunosti irelevantan za opaŹeni rast cijena stambenih nekretnina. Točnije, uzimajući u obzir visoku zastupljenost privatnog smještaja u Hrvatskoj i nedavnog porasta broja nekretnina za kratkoročni najam, trajni je pritisak turizma na tržište stambenih nekretnina učinio ponudu stambenih nekretnina neelastičnom. To je u konačnici dovelo i do povećanja cijena nakon uvođenja subvencioniranih kredita. Zbog tog su razloga subvencije stambenih kredita djelovale kao prociklični pokretač dodatnih cjenovnih pritisaka na već tijesnom i neelastičnom tržištu stambenih nekretnina.

Do zanimljive promjene u provedbi subvencioniranja stambenih kredita došlo je 2018. kada je uvedena diferencirana stopa subvencioniranja ovisno o razini razvoja općine ili grada u kojemu se stambena nekretnina nalazi. U 2018. i 2019. je godini umjesto prije propisanog 50%-tnog pokrića anuiteta subvencija mogla iznositi od 30% u najrazvijenijim gradovima i općinama do najviše 51% u najmanje razvijenima. Takva struktura programa subvencioniranja omogućuje nam izravnu procjenu utjecaja *intenziteta* subvencije s pomoću geografskih diskontinuiteta koje implicira *indeks razvijenosti*. Nalazimo da se relativne cijene stambenih nekretnina s višom implicitnom stopom subvencije, u usporedbi sa stambenim nekretninama s nižom stopom subvencije, nisu mijenjale nakon uvođenja programa subvencioniranja stambenih kredita, što upućuje na to da *intenzitet* subvencije nije doveo do značajnog učinka dodatnog porasta cijena. Ti rezultati upućuju na to da je do porasta cijena stambenih nekretnina došlo u bogatijim regijama, u kojima je ionako tržište stambenih nekretnina aktivnije i u kojima je ponuda stambenih nekretnina neelastična.

2. Institucionalno okruŹje i subvencioniranje stambenih kredita

U lipnju 2017. Hrvatski sabor donio je *Zakon o subvencioniranju stambenih kredita*.¹ Cilj je Zakona omogućiti lakše stjecanje stambenih nekretnina mladima do 45 godina i tako potaknuti demografsku obnovu, regenerirati urbana područja i preokrenuti postojeći negativan trend iseljavanja. U osnovi se Zakonom regulira mogućnost da država pokriva dio anuiteta u početnom razdoblju otplate stambenoga kredita. Zakonom se pritom ne uređuje tržište nekretnina, već kućanstva sama dogovaraju kupnju nekretnine i odlučuju se za komercijalnu banku koja će tu kupnju financirati

¹ Zakon o subvencioniranju stambenih kredita (NN, br. 65/2017., 61/2018. i 66/2019.)

i tek kada se postigne dogovor o ugovoru i kada se kredit odobri, kućanstvo moŹe podnijeti zahtjev za subvenciju. Subvencije se provode preko Agencije za pravni promet i posredovanje nekretninama koja oglašava subvencije, prikuplja zahtjeve te provjerava ispunjavaju li oni kriterije i odobrava subvencije. U razdoblju od 2017. do 2019., koje je predmet naše analize, zahtjevi za subvencije zapimali su se unutar mjesec dana, obično s početkom u rujnu.²

U prvom krugu podnošenja zahtjeva, koji je trajao od 4. rujna do 13. listopada 2017., vrijedili su sljedeći uvjeti:

- Subvencije stambenih kredita odobravaju se pojedincima do 45 godina starosti koji nemaju stan ili kuću u svom vlasništvu, ili čiji partneri nemaju stan ili kuću u svom vlasništvu, a ako imaju, planiraju ih prodati kako bi kupili veću (ili primjereniju) nekretninu.
- Subvencija se moŹe iskoristiti za kupnju stanova i kuća i za izgradnju kuća, a svaka nekretnina treba imati potrebne dozvole. Subvencija se odobrava na iznose do 100.000 eura i za cijenu od 1500 eura po kvadratnom metru.³ Subvencije se odobravaju i za skuplje nekretnine, no samo do navedenih iznosa.
- Minimalno razdoblje dospijeaća stambenoga kredita na koji se primjenjuje subvencija iznosi 15 godina, uz efektivnu kamatnu stopu od najviše 3,75% u prve četiri godine te povećanu za najviše 10% u iduće dvije godine.
- Ako su ispunjeni svi kriteriji i subvencija je odobrena, subvencionira se polovina anuiteta tijekom prve četiri godine kredita.⁴ Trajanje subvencije moŹe se produljiti za još dvije godine za svako novorođeno ili posvojeno dijete u kućanstvu.

U drugom krugu subvencija, koji je trajao od 3. rujna do 5. listopada 2018., vrijedili su jednaki uvjeti kao i u prvom krugu iz 2017. uz nekoliko važnih izmjena:

- Iznos subvencije varira po općinama i kretao se od 30% do 51%, ovisno o klasifikaciji općine prema indeksu razvijenosti, odnosno kompozitnom indeksu prema kojem se 556 općina i gradova u Hrvatskoj svrstava u osam razvojnih skupina.⁵ Postotak subvencije sada je ovisio o skupini – što je manje razvijena

² Od 2020. subvencije su se odobravale u dva kruga, jedan u proljeće, a drugi u jesen, no zbog nedostatka podataka ne analiziramo učinke iz krugova provedenih u 2020.


³ Medijan cijene po kvadratnom metru stanova u Hrvatskoj u razdoblju od 2015. do 2017. iznosio je otprilike 1090 eura, a 75. percentil iznosio je otprilike 1400 eura.

⁴ ProduŹuje se za još jednu godinu ako bilo koji član kućanstva ima stopu invaliditeta veću od 50%.

⁵ Indeks razvijenosti izraćunava se na temelju podataka općina o prosječnom dohotku po glavi stanovnika, prosječnim prihodima po glavi stanovnika, prosječnoj stopi nezaposlenosti, populacijskoj dinamici i udjelu tercijarnog obrazovanja te demografskih pokazatelja. VaŹeaća verzija indeksa razvijenosti primjenjuje se od početka 2018. i vrijedit će do početka 2021., kada će se početi primjenjivati nova, ažurirana verzija tog indeksa.

općina, to je veća subvencija. Na Slici 2. prikazujemo iznos potencijalne subvencije stambenih kredita u 2018.:

Slika 2. Potencijalna subvencija stambenih kredita u 2018.



- Trajanje subvencije također se povećalo s četiri na pet godina i subvencija se može produljiti za još dvije godine za svako novorođeno ili posvojeno dijete u kućanstvu.⁶


U trećem krugu subvencija, koji je trajao od 10. rujna do 4. listopada 2019., uglavnom su vrijedili jednaki uvjeti kao i u onom iz 2018. s nekoliko izmjena:

⁶ Također se produljuje za dvije godine ako član kućanstva ima stupanj invaliditeta veći od 50%.

- Ako je kućanstvo imalo maloljetno dijete prije subvencije, njezino se trajanje produljuje za godinu dana, a ako kućanstvo dobije ili posvoji dijete za vrijeme trajanja subvencije, trajanje subvencije produljuje se za još dvije godine.⁷

Program subvencioniranja stambenih kredita vrlo je brzo postao popularan te je od 2017. do 2019. podneseno ukupno 9692 zahtjeva (2399 u 2017., 3033 u 2018. i 4260 u 2019.) od čega ih je 9403 bilo odobreno i financirano (2306 u 2017., 2946 u 2018. i 4151 u 2019.), što čini nešto više od 12% ukupnog obujma transakcija na tržištu stambenih nekretnina. Osnovna obilježja programa subvencioniranja prikazana su na Slici 3.⁸

Slika 3. Subvencioniranje stambenih kredita u 2017. i 2018.



Izvor: Agencija za pravni promet i posredovanje nekretninama

Vidimo da se subvencioniranje stambenih kredita u 2017. i 2018. uglavnom upotrebljavalo za kupnju stana (68%) i da se većina subvencija, mjereno brojem subvencija, odnosila na razvijenije općine i gradove (Slika 3.b)), koji imaju viši indeks razvijenosti. Na Grad Zagreb, glavni grad Hrvatske, otpada velik dio tih razvijenih općina i gradova te se na njega odnosi 33,4% subvencija i on općenito čini trećinu tržišta nekretnina u Hrvatskoj.

Razlog zbog kojeg su subvencionirani stambeni krediti relativno popularni jest činjenica da oni osiguravaju očitu financijsku injekciju kućanstvu. Primjerice, u 2017., kada je subvencija pokrivala 50% anuiteta tijekom prve četiri godine otplate, prosječan je stambeni kredit iznosio 67.500 eura, uz prosječnu efektivnu kamatnu stopu od 3,30% i prosječno trajanje kredita od 20 godina.⁹ Na primjeru jednostavnog izračuna mjesečnog

⁷ Za detaljnije informacije o subvenciji vidi Okvir 4. (str. 35) u HNB (2019.) i službenu stranicu o subvencijama: APN (2020.c).

⁸ Nemamo pristup disagregiranim podacima za 2019.

⁹ Za više informacija vidi APN (2020.a) i APN (2020.b).

anuiteta bez depozita, te imajući na umu da ti prosjeci možda ne predstavljaju prosječni kredit, dobivamo da je anuitet iznosio otprilike 380 eura mjesečno. To znači da je tijekom razdoblja od četiri godine subvencija iznosila otprilike 190 eura mjesečno, što ukupno iznosi 9120 eura ili otprilike 10% ukupnog iznosa kredita. Za više informacija o tržištu nekretnina u Hrvatskoj vidi Tkalec *et al.* (2018.) i Rašić *et al.* (2019.).

3. Podaci i empirijski pristup


Za detaljnu analizu učinka subvencioniranja stambenih kredita na tržište nekretnina koristimo se mikropodacima Porezne uprave Ministarstva financija koji obuhvaćaju sve stambene transakcije u Hrvatskoj. Baza podataka kojom se služimo obuhvaća razdoblje od 2015. do 2019., uključujući navedene godine, i sadržava različite značajke stambenih transakcija, poput vrste stambene nekretnine (kuće ili stanovi), cijene i veličine, lokacije, vremena prodaje, godine izgradnje i stanja nekretnine te pokazatelje koji se odnose na inozemne prodavatelje i kupce. Treba napomenuti da nemamo pristup podacima o tome koje su transakcije finalizirane sa subvencioniranim kreditima, što je donekle ograničavajući faktor, no ne u velikoj mjeri s obzirom na to da nas zanima učinak subvencija na cijelo tržište nekretnina, uključujući i učinke prelijevanja, a ne samo na transakcije sa subvencijama. Budući da baza podataka sadržava pogreške, posebice vezano uz veličinu stambene nekretnine, što se zatim ogleda u pogreškama u cijenama po kvadratnom metru, ne uzimamo u obzir transakcije koje su imale cijenu u 2,5% najviših i najnižih cijena po kvadratu. Deskriptivna statistika prikazana je u tablici navedenoj u nastavku. Za detaljniji opis baze podataka vidi Kunovac i Kotarac (2019.).

Slika 4. prikazuje dinamiku stambenih transakcija u razdoblju između 2015. i 2019., iz koje možemo zaključiti da se tržište nekretnina, posebice stanova koji su često kupovani uz korištenje subvencije (vidi Sliku 3.a), znatno promijenilo od uvođenja subvencioniranih stambenih kredita. U listopadu 2017., 2018. i 2019., mjesecu u kojem završava podnošenje zahtjeva, tržište nekretnina doživljava vrhunac glede broja transakcija, nakon čega je uslijedio snažan pad do sljedećeg kruga subvencija, kada tržište opet doseže vrhunac. To se ne odnosi samo na broj transakcija već i na ukupnu tržišnu vrijednost¹⁰. Zanimljivo je da se ukupan broj transakcija tijekom cijele godine ne mijenja značajno s uvođenjem subvencija, što upućuje na to da su subvencionirani stambeni krediti utjecali na preraspodjelu i koncentraciju uobičajenog obujma stambenih transakcija tijekom rujna i listopada. To je samo po sebi značajna implikacija programa, jer je njime očigledno došlo do poremećaja dinamike obujma transakcija unutar godine.


¹⁰ Rezultati izostavljeni radi kratkoće

Slika 4. Broj prodanih stanova i kuća


a) Prodani stanovi




b) Prodane kuće




c) Toplinska karta prodanih stanova




d) Toplinska karta prodanih kuća



e) Stanovi



f) Kuće



Tablica 1. Deskriptivna statistika kuća i stanova, 2015. – 2019.

	Stanovi		Kuće	
Kontinuirane varijable	Prosjek	Standardna devijacija	Prosjek	Standardna devijacija
Cijena u eurima	68.972,75	39.912,68	78.917,80	100.537,87
Veličina u m ²	58,08	23,19	140,27	149,32
Starost nekretnine	35,40	33,40	59,97	45,63
Indikatorske varijable	Prosjek (%)	–	Prosjek (%)	–
Inozemni kupci	6,79	–	15,00	–
Stanje				
Potrebna adaptacija	10,53	–	22,08	–
Dobro	22,76	–	13,57	–
Luksuzno	0,79	–	0,20	–
Podaci nedostupni	65,93	–	64,15	–
Godina transakcije				
2015.	14,06	–	15,26	–
2016.	19,14	–	18,64	–
2017.	22,55	–	21,73	–
2018.	21,12	–	21,04	–
2019.	23,13	–	23,34	–
Opažanja	79.026		12.078	

3.1. Analiza studije događaja

Kako bismo ispitali je li uvođenje subvencioniranih stambenih kredita utjecalo na cijene, koristimo se analizom studije događaja koja je primijenjena s pomoću standardne hedonističke regresije. Kao što se vidi iz Slike 4., dinamika prodaje stambenih nekretnina promijenila se nakon uvođenja subvencija, a ovaj nam pristup omogućuje da analiziramo jesu li se promijenile i *cijene* stambenih nekretnina. Procjenjujemo:

$$\ln(cijena_i) = \sum_{k=1}^T \delta_k D_{ik} + \alpha X_i + \sum_{j=1}^J \beta_j B_{ij} + \epsilon_i \quad (1)$$

gdje je:

- $cijena_i$ cijena po kvadratnom metru stambene jedinice i
- D_{ik} je indikatorska (“dummy”) varijabla čija je vrijednost 1 ako je stambena jedinica i prodana u mjesecu k , odnosno 0 ako nije
- X_i označava vektor karakteristika stambene jedinice i ; on uključuje deset skupina indikatorskih varijabla za veličinu stambene nekretnine, deset skupina indikatorskih varijabla za godinu izgradnje (vrijednosti koje nedostaju označene su kao zasebna skupina), tri skupine indikatorskih varijabla za stanje

- stambene nekretnine (vrijednosti koje nedostaju označene su kao zasebna skupina) i pokazatelje koji se odnose na inozemne kupce i prodavatelje
- B_{ij} je indikatorska varijabla čija je vrijednost 1 ako se stambena jedinica i nalazi u općini j , odnosno 0 ako se ne nalazi u toj općini. Stoga β_j označava fiksne učinke općine koji uzimaju u obzir sve neopažene vremenski invarijantne značajke na razini općine. Budući da Hrvatska ima 556 općina i gradova, uključivanje tih fiksnih učinaka omogućuje uzimanje u obzir niza važnih karakteristika nekretnina, poput udaljenosti od obale (što je važan pokazatelj za turizam), veličine općine, razine urbanizacije i ostalih karakteristika koje se ne mijenjaju s vremenom.

Literatura o hedonističkom vrednovanju nekretnina oslanja se na parametre δ_k koji predstavljaju dinamiku cijena stambenih nekretnina tijekom vremena. Kao što je detaljnije opisano u srodnoj literaturi o hedonističkim indeksima cijena, omjer $\exp(\delta_k)/\exp(\delta_s)$, gdje je s bazno razdoblje, daje približnu vrijednost rasta cijene stambene nekretnine s proizvoljnim skupom karakteristika tijekom razdoblja $t=s$ do $t=k$. Ako je δ_s nula, $\exp(\delta_k)$ uspoređuje cijene stambenih nekretnina u razdoblju $t=k$ s onima u baznom razdoblju. Kunovac i Kotarac (2019.) detaljnije objašnjavaju ovu aproksimaciju hedonističkog indeksa cijena (i njegovu eventualnu pristranost). U kontekstu naše analize promatranjem $\exp(\delta_k)$ možemo detektirati i potencijalno povećanje cijena uzrokovano upravo programom državnih subvencija. Važno svojstvo ovog pristupa leži u činjenici da eksplicitno ne namećemo nikakvu strukturu vremenskom učinku, već samo ispitujemo mijenjaju li se ti vremenski učinci nakon uvođenja subvencioniranja stambenih kredita. Treba napomenuti da na taj način procjenjujemo učinak namjere subvencije (engl. *intent-to-treat*), što je atraktivna značajka jer nas zanimaju učinci prelijevanja te mjere, a ne samo njezin utjecaj na subvencionirane transakcije. Procjene $\exp(\delta_k) \times 100$, procijenjene odvojeno za stanove i kuće, prikazane su na Slici 5.¹¹

Osnovni rezultati pokazuju da su cijene stambenih jedinica, posebice stanova (Slika 5.a)), u prosjeku znatno porasle nakon uvođenja subvencioniranih stambenih kredita kada je i došlo do promjena u obujmu transakcija (vidi Sliku 4.). Na primjer, u listopadu 2017. kada je zaključen prvi krug poziva za subvencije, cijene stanova bile su za 6,18% više nego u siječnju 2015. Činjenica da je to bilo prvo signifikantno povećanje cijena u promatranom razdoblju govori u prilog tomu da su subvencionirani stambeni krediti uistinu potaknuli rast cijena. Nakon subvencija iz 2017. cijene stanova pale su, no ponovno su porasle u kolovozu 2018. kada je najavljen sljedeći krug subvencija. Od tada su cijene stalno rasle i dosegnule su vrhunac na kraju 2019., kada su cijene stanova porasle za 16,9% u odnosu na one iz siječnja 2015. Kretanje cijena kuća po kvadratnom metru (Slika 5.b)) upućuje na ponešto različite zaključke. Osim privremenog porasta


¹¹ Osnovne procjene prikazane su i u Tablici 3. u Dodatku, a ostatak tablice s procjenama može se dobiti na zahtjev.


cijena, opet u listopadu 2017. kada su uvedene subvencije (snažno povećanje od strelovitih 26,48%), ne vidimo učinak subvencioniranja stambenih kredita na rast cijena. Ta razlika u utjecaju na cijene stanova i kuća i ne čudi previše ako uzmemo u obzir da se više od dvije trećine subvencija odnosilo na kupnju stanova (barem u 2017. i 2018., za koje imamo podatke o subvencioniranju, vidi Sliku 3.a).

Kako bismo potvrdili naše osnovne tvrdnje i detaljnije dokumentirali učinak subvencioniranja, provodimo analizu i na razini županija (Slika 6.), koja pokazuje da je Grad Zagreb, na koji odlazi trećina subvencija, zabilježio najveći rast cijena stanova. Uzimajući u obzir nejednaku raspodjelu subvencija među različitim razvojnim skupinama (Slika 3.b)), provodimo zasebnu studiju događaja za svaku skupinu i zaključujemo da su samo najrazvijenije općine i gradovi (s indeksom razvoja 8), koji su apsorbirali najveći dio subvencija, zabilježili stalan rast cijena (Slika 16.). Treba napomenuti da je i u pomoćnim analizama učinak na cijene stanova bio prisutan, dok učinak na cijene kuća izostaje.

Kako bismo dodatno ispitali je li ustanovljena veza između uvođenja subvencija i povećanja cijena slučajna, i/ili da na nju utječu ostali čimbenici, npr. opća gospodarska situacija, može biti korisno analizirati i dvije značajke subvencija stambenih kredita u sve tri godine:

Slika 5. Analiza studije događaja logaritma cijene po m²





Bilješka: Točke prikazuju procjene vremenskih učinaka ($\exp(\delta_k) \times 100$; u odnosu na siječanj 2015.), a stupci prikazuju 99%-tne intervale pouzdanosti na temelju standardnih pogrešaka grupiranih na razini općina. Kontrolne varijable uključuju deset skupina indikatorskih varijabla za veličinu stambene nekretnine, deset skupina za godinu izgradnje (nedostajuće vrijednosti kodirane su kao posebna skupina i uključene u specifikaciju), tri skupine indikatorskih varijabla za stanje stambene nekretnine (nedostajuće vrijednosti kodirane su kao posebna skupina i uključene u specifikaciju), pokazatelje koji se odnose na inozemnog kupca i prodavatelja i fiksni učinak općina. Crveni stupci prikazuju utjecaje značajne na 99%-tnoj razini.

- Subvencija se primjenjivala samo na iznose do 100.000 eura, što znači da su manji stanovi imali veći dio anuiteta pokrivenog subvencijama.
- Subvencija se primjenjivala samo na iznos do 1500 eura po kvadratnom metru, što znači da su stanovi jeftiniji po kvadratnom metru imali veći dio svog anuiteta pokrivenog subvencijama.

Ove dvije značajke možemo parametrizirati s pomoću dviju zadanih varijabla:

- veličine stana u kvadratnim metrima
- godine izgradnje stana kao važne odrednice cijene po kvadratnom metru.¹²


Slika 17. u Dodatku pokazuje da je ukupna cijena u 2015. i 2016. (prije uvođenja subvencioniranja stambenih kredita) funkcija veličine stana, a jedinična je cijena funkcija godine izgradnje. Koristeći se tim dvjema značajkama u kombinaciji s pravilima za provedbu subvencioniranja stambenih kredita, osiguravamo dodatnu razinu empirijske provjere – ako je subvencioniranje stambenih kredita zaista uzrokovalo porast cijena, trebali bismo uočiti značajnije pomake u cijenama za relativno više subvencionirane stanove, odnosno manje stanove i one jeftinije po kvadratnom metru.

¹² Za otprilike petinu transakcija koje uključuju stanove nedostaje stavka u varijabli godina izgradnje.


Na primjer u kolovozu 2017., nešto prije uvođenja subvencija, prosječna cijena stana po kvadratnom metru u Hrvatskoj iznosila je otprilike 1100 eura, što znači da bi cijela vrijednost stana od 50 kvadratnih metara bila pokrivena subvencijom, dok bi pokrivenost subvencijom stana od 120 kvadratnih metara iznosila samo 75% (*ceteris paribus*). To znači sljedeće: da je opaženo povećanje cijena zaista bilo potaknuto subvencioniranjem stambenih kredita, ako uzmemo u obzir činjenicu da je veličina unaprijed zadana značajka, primijetili bismo da manji stanovi imaju veće pomake u cijeni.

Slika 6. Studija događaja po županijama (šest županija s najviše transakcija)

a) Stanovi



b) Kuće





Napomena: Točke prikazuju procjene vremenskih učinaka ($\exp(\delta_k) \times 100$; u odnosu na siječanj 2015.), a stupci prikazuju 99%-tni interval pouzdanosti koji se zasniva na standardnim pogreškama grupiranim na razini općina. Kontrolne varijable uključuju deset skupina indikatorskih varijabla za veličinu stambene nekretnine, deset skupina indikatorskih varijabla za godinu izgradnje (nedostajuće vrijednosti kodirane su kao posebna skupina i uključene u specifikaciju) i pokazatelje koji se odnose na inozemnog kupca i prodavatelja. Crveni stupci prikazuju utjecaje značajne na 99%-tnoj razini.

Formalno to ispitujemo zasebnom procjenom jednadžbe 1 za stanove različite veličine i različite starosti. Koristimo se pritom istom specifikacijom, no izostavljamo indikatorske varijable za veličinu odnosno godinu izgradnje. Rezultati su prikazani na Slici 7. tj. Slici 7.a) koja prikazuje rezultate za stanove različitih veličina i pokazuje da su cijene manjih stanova zaista znatno porasle u vrijeme uvođenja subvencioniranja stambenih kredita dok subvencije nisu znatno utjecale na cijene većih stanova, posebice onih većih od 80 kvadratnih metara. Isti zaključak proizlazi iz Slike 7.b), iz koje se vidi da su stanovi novije izgradnje imali manji pomak u cijeni. Prikazani su rezultati u skladu s inicijalnim tumačenjem naših prethodnih rezultata – uvođenje subvencioniranja stambenih kredita znatno je promijenilo dinamiku tržišta stambenih nekretnina i dovelo do povećanja cijena stanova. Naše „kontrolne“ skupine (veći stanovi i stanovi novije izgradnje) također mogu biti subvencionirane (tretirane), iako u manjem opsegu te stoga ocjenjujemo da su dobivene procjene niža granica stvarnih vrijednosti.¹³

Ukratko, provedena analiza u skladu je sa stajalištem prema kojem je promjena u obujmu transakcija u vrijeme uvođenja subvencioniranja stambenih kredita potaknula trajno povećanje cijena, poglavito cijena stanova koji su češće predmet subvencija. Činjenica da je za manje i starije stanove koji su bili relativno više tretirani i za stanove u razvijenijim općinama koji su apsorbirali više subvencija, zabilježen snažniji rast cijena, navodi na zaključak da je uvođenje subvencioniranja stambenih kredita uistinu potaknulo promjene cijena nekretnina.

¹³ Na taj način također procjenjujemo dinamičku verziju razlike u razlici. Budući da rezultati samo odražavaju zaključke prikazane na Slici 7., izostavljamo ih radi kratkoće. Treba napomenuti da te podatke ne prikazujemo za kuće jer oni potvrđuju zaključak o izostanku učinka.

Slika 7. Analiza studije događaja logaritma cijene po m² prema veličini i starosti stana**a) Gradijent veličine****b) Gradijent godine izgradnje**

Bilješka: Točke prikazuju procjene vremenskih učinaka ($\exp(\delta_k) \times 100$; u odnosu na siječanj 2015.), a stupci prikazuju 99%-tne intervale pouzdanosti na temelju standardnih pogrešaka grupiranih na razini općina. Kontrolne varijable uključuju deset skupina indikatorskih varijabla za godinu izgradnje (nedostajuće vrijednosti kodirane su kao posebna skupina i uključene u specifikaciju), tri skupine indikatorskih varijabla za stanje stambene nekretnine (nedostajuće vrijednosti kodirane su kao posebna skupina i uključene u specifikaciju), pokazatelje koji se odnose na inozemnog kupca i prodavatelja i fiksni učinak općina. Crveni stupci prikazuju utjecaje značajne na 99%-tnoj razini.

3.2. Međunarodne cijene stambenih nekretnina

Kako bismo analizirali mogućnost da je opaženi porast cijena potaknut nekim drugim čimbenicima, a ne nužno državnim subvencijama, ispitujemo i utjecaj međunarodnog odnosno globalnog ili europskog ciklusa cijena stambenih nekretnina.

Iako kupovina stambene nekretnine za većinu kućanstava ne može biti “supstituirana” kupnjom nekretnine u inozemstvu, cijene nekretnina općenito mogu imati snažnu *zajedničku međunarodnu komponentu*.¹⁴ Takva povezanost, primjerice, može odražavati sličnosti u fundamentima koji određuju cijene, uvjetima financiranja ili premijama za rizik u različitim zemljama i ona dodatno raste u uvjetima snažnih ekonomskih i financijskih veza među zemljama (Vansteenkiste i Hiebert, 2011.). Rast ove zajedničke komponente cijena stambenih nekretnina do kojeg dolazi istodobno s uvođenjem državnih subvencija u Hrvatskoj bi stoga govorio u prilog stajalištu da su neki drugi čimbenici, uz državni program, mogli imati dominantnu ulogu u pokretanju inflacije cijena stambenih nekretnina posljednjih godina.


Kako bismo ocijenili relativnu važnost zajedničkoga financijskog ciklusa i nacionalne specifičnosti za cijene stambenih nekretnina u Hrvatskoj, iz cijena stambenih nekretnina skupine od 20 europskih zemalja najprije ekstrahiramo njihov zajednički ciklus¹⁵ i uspoređujemo ga s ciklusom cijena stambenih nekretnina u Hrvatskoj.¹⁶ Koristeći se tzv. *bandpass* filtrom iz Christiano i Fitzgerald (2003.), za svaku zemlju izdvajamo relativno kratke cikluse na frekvencijama između dvije i osam godina koje se obično povezuju s trajanjem *poslovnog ciklusa*. Nadalje, izdvajamo i duže cikluse, u trajanju od osam do petnaest godina, koji su obično povezani s ciklusima u cijenama stambenih nekretnina odnosno, u širem smislu, predstavljaju *financijske cikluse* (Drehmann *et al.*, 2012.; Rünstler i Vlekke, 2018.; Comin i Gertler, 2006.). Nakon toga, primjenom analize glavnih komponenata (*principal components analysis*, PCA) ekstrahiramo zajedničke komponente iz skupine (nominalnih) cijena stambenih nekretnina na frekvencijama poslovnog i financijskog ciklusa. Konačno, kako bi se odredila relativna važnost zajedničkoga europskog ciklusa u odnosu na nacionalne specifičnosti za cijene stambenih nekretnina u Hrvatskoj, cikluse cijena stambenih nekretnina u Hrvatskoj, na kraćim i duljim frekvencijama, uspoređujemo s glavnim komponentama ekstrahiranim iz skupine europskih cijena nekretnina. Glavni nalazi prikazani su na Slici 8. i mogu se sažeti kako slijedi.

¹⁴ Kunovac *et al.* (2018.) i Rünstler *et al.* (2018.) pokazuju da zajednička sastavnica cijena stambenih nekretnina ima mnogo manje značenje za zemlje od BDP-a.

¹⁵ Našom su analizom obuhvaćene ove države: Belgija, Bugarska, Češka, Danska, Estonija, Finska, Francuska, Hrvatska, Irska, Letonija, Litva, Mađarska, Nizozemska, Njemačka, Norveška, Poljska, Portugal, Slovačka, Slovenija, Španjolska i Švedska. Analiza glavnih sastavnica provodi se na temelju podataka o cijenama stambenih nekretnina od prvog tromjesečja 2008. do četvrtog tromjesečja 2019.

¹⁶ Usporedbom ciklusa stambenih nekretnina u Hrvatskoj s ciklusom stambenih nekretnina u Europi implicitno uzimamo u obzir fundamente i njihov utjecaj na tržište stambenih nekretnina.

Slika 8. Ciklusi cijena stambenih nekretnina



Cijene stambenih nekretnina u Hrvatskoj pokazuju značajne fluktuacije na dvije frekvencije (Slika 8.b)). Prva glavna komponenta objašnjava oko 45% ukupne varijacije svih cijena u Europi na frekvenciji poslovnog ciklusa, a na frekvenciji financijskog ciklusa mnogo više – otprilike 66%. Većina pada cijena stambenih nekretnina u razdoblju od globalne financijske krize, s 5% iznad trenda na –8% ispod trenda, može se objasniti kretanjima na tim srednjoročnim frekvencijama financijskog ciklusa. Te su fluktuacije korelirane sa zajedničkom europskom komponentom, iako s određenim pomakom (Slika 8.c)). S druge strane, na frekvenciji poslovnog ciklusa, fluktuacije cijena stambenih nekretnina općenito su bile manjih amplituda. Najvažniji nalaz za našu analizu jest da, za razliku od srednjoročnih fluktuacija na frekvencijama financijskog ciklusa, cijene stambenih nekretnina u Hrvatskoj upućuju na znatan idiosinkratski rast u frekvencijama poslovnog ciklusa koji se događa istodobno s uvođenjem državnih subvencija (Slika 8.d)). Odnosno, uz rast prethodno karakteriziran duljim (financijskim) ciklusima, cijene stambenih nekretnina dodatno su porasle s otprilike –1,5% na otprilike 3,5% iznad trenda od početka provedbe državnog programa subvencioniranja stambenih kredita.

Ova jednostavna analiza kretanja ciklusa cijena stambenih nekretnina u Hrvatskoj i drugim europskim zemljama govori u prilog stajalištu da je rast cijena stambenih nekretnina u Hrvatskoj koji je započeo 2015. bio uglavnom u skladu s kretanjima u međunarodnom financijskom ciklusu u tom razdoblju. Međutim, pronalazimo dokaze o inflaciji cijena stambenih nekretnina u Hrvatskoj koja je uglavnom specifična za

domaće tržište. Pritom je važno naglasiti da idiosinkratski dio ciklusa cijena stambenih nekretnina u Hrvatskoj počinje biti bitan upravo usporedno s uvođenjem programa subvencioniranja stambenih kredita.

3.3. Turistička aktivnost i cijene stambenih nekretnina u Hrvatskoj

U ovom poglavlju ispituje se mijenja li uključivanje turizma kao važne odrednice tržišta stambenih nekretnina u analizu naše rezultate. Stajalište da su stambene nekretnine skuplje u općinama i gradovima koji imaju *više turizma*, empirijska je činjenica (vidi, primjerice, odjeljak 6. u radu Tkalec *et al.*, 2018.), no ostaje pitanje utječe li više turizma izravno na cijene *unutar* određene općine na vremenskoj, a ne samo na geografskoj razini. Točnije, je li moguće da opažena promjena u cijenama u listopadu 2017. koju pripisujemo uvođenju subvencioniranja stambenih kredita, zapravo proizlazi iz promjene u turističkoj aktivnosti, koja stvara trajni pritisak na ponudu stambenih nekretnina. Kako bismo ispitali ulogu turizma kao varijable koja objašnjava tržište nekretnina, a koju nismo uključili u osnovni model, prikazujemo rezultate triju pomoćnih analiza.

Prvo, u okvir studije događaja uključujemo godišnje podatke o turizmu na razini općina:

$$\ln(cijena_i) = \sum_{k=1}^T \delta_k D_{ik} + \alpha X_i + \sum_{j=1}^J \beta_j B_{ij} + \gamma T_i + \epsilon_i \quad (2)$$

gdje koeficijenti δ_k za razliku od prethodnih specifikacija sada prate kretanje cijena na godišnjoj razini, T_i označava broj turističkih noćenja po glavi stanovnika u općini j u vremenu k , tako da parametar γ ¹⁷ obuhvaća utjecaj turizma na cijene stambenih nekretnina.¹⁸ Ovim pristupom možemo obuhvatiti dinamiku turizma koja je povezana s određenom općinom. Ako turistička aktivnost potiče opaženi porast cijena stambenih nekretnina, može se očekivati da će se veličina i značenje koeficijenta uz vremenske indikatorske varijable mijenjati s uključivanjem varijabla za turizam. Glavno je ograničenje ovdje činjenica da nemamo mjesečne ili tromjesečne podatke o turizmu na razini općina koji se protežu kroz promatrano razdoblje, tako da analizu provodimo na godišnjoj razini. Slika 9. prikazuje rezultate s turizmom i bez turizma, zasebno za stanove i kuće. Procjena s turizmom i bez turizma prilično je slična i potvrđuju se svi glavni zaključci – cijene stambenih nekretnina znatno su porasle u 2017. bez obzira na turizam.


¹⁷ Treba napomenuti da smo, kako bismo omogućili nelinearnost, u specifikaciju uključili linearnu i nelinearnu dimenziju turizma.

¹⁸ Broj turističkih noćenja, barem u jednoj od promatranih godina, bio je zabilježen u 236 od 556 općina te su one isključene iz analize. Međutim, na preostalim 320 općina otpada otprilike 95% svih stambenih transakcija iz uzorka.

Kako bismo fleksibilnije ispitali utjecaj turizma na cijene stambenih nekretnina, procjenjujemo i vremenski varijabilan koeficijent uz turizam. Procjenjujemo jednadžbu 2, no s pet varijabli za turizam, po jednu za svaku godinu iz uzorka. Rezultati ove specifikacije, uz osnovnu procjenu iz jednadžbe 2, prikazani su u Tablici 2. Jasan je zaključak da je porast cijena stambenih nekretnina, posebno stanova, značajan, čak i ako uzmemo u obzir turističku aktivnost u različitim specifikacijama. Zanimljivo je da ni u jednom stupcu Tablice 2. koeficijent uz turizam nije značajan u objašnjavanju cijena stambenih nekretnina. Razlog je taj što u specifikacije uključujemo fiksne utjecaje općina koji obuhvaćaju geografske značajke, prije svega udaljenost od obale. Stoga, kad uzmemo u obzir općine u priobalju, više turizma kroz vrijeme ne prelijeva se u više cijene stambenih nekretnina. Budući da je geografija fiksno obilježje na koje se ne može utjecati, dok se na turističku aktivnost može, smatramo da je to korisna informacija koja potvrđuje naše osnovne zaključke. Nadalje, drugi stupac pokazuje da se utjecaj turizma na cijene stambenih nekretnina, koje su procijenjene za svaku godinu zasebno, ne mijenjaju tijekom cijelog razdoblja uzorka.

Taj rezultat zapravo ne čudi ako pogledamo dinamiku turističkog rasta i rasta cijena stambenih nekretnina u Hrvatskoj (vidi Sliku 10.).

Slika 9. Analiza studije događaja logaritma cijene po kvadratnom metru na razini godine



Bilješka: Točke prikazuju procjene vremenskih učinaka ($\exp(\delta_k) \times 100$; u donosu na 2015.), a stupci prikazuju 99%-tne intervale pouzdanosti zasnovane na standardnim pogreškama grupiranim na razini općina. Kontrolne varijable uključuju deset skupina indikatorskih varijabli za veličinu stambene nekretnine, deset skupina indikatorskih varijabli za godinu izgradnje (nedostajuće vrijednosti kodirane su kao posebna skupina i uključene u specifikaciju), tri skupine indikatorskih varijabli za stanje stambene nekretnine (nedostajuće vrijednosti kodirane su kao posebna skupina i uključene u specifikaciju), pokazatelje koji se odnose na inozemnog kupca i prodavatelja i fiksni učinak općina te broj turističkih noćenja na razini općine (slika b). Crveni stupci prikazuju utjecaje značajne na 99%-tnoj razini.


Tablica 2. Usporedba dviju različitih specifikacija s turizmom

	Stanovi			Kuće
	(1)	(2)	(3)	(4)
Vremenski učinci (odnosi se na 2015.)				
2016.	0,006 (0,010)	0,01 (0,009)	-0,054* (0,030)	0,07** (0,036)
2017.	0,024 (0,021)	0,022 (0,021)	0,048 (0,033)	0,028 (0,034)
2018.	0,058*** (0,019)	0,058*** (0,017)	0,076** (0,039)	0,053 (0,034)
2019.	0,133*** (0,033)	0,138*** (0,030)	0,104* (0,054)	0,098* (0,053)
Turizam	0,0002 (0,001)		0,001 (0,002)	
Kvadrirani pokazatelj turizma	-0,00000 (0,00000)		0,00000 (0,00000)	
Učinci turizma				
2015.		0,0004 (0,001)		-0,00002 (0,002)
2016.		0,0003 (0,001)		0,0002 (0,001)
2017.		0,0004 (0,001)		0,0004 (0,001)
2018.		0,0004 (0,001)		0,0004 (0,001)
2019.		0,0003 (0,001)		0,0002 (0,001)
Deset indikatorskih varijabla za veličinu	da	da	da	da
Deset indikatorskih varijabla za starost	da	da	da	da
Tri indikatorske varijable za stanje	da	da	da	da
Indikatorske varijable za inozemnog kupca i prodavatelja	da	da	da	da
Fiksni učinci općina	da	da	da	da
Opažanja	78.001	78.001	11.656	11.656
Prilagođeni R ²	0,453	0,453	0,477	0,477
Rezidualna standardna pogreška	0,298	0,298	0,706	0,706

Napomena: Tablica prikazuje procijenjene koeficijente iz jednadžbe 2 (stupci (1) i (3)) i specifikacija s vremenskim učinkom turizma (stupci (2) i (4)). Standardne pogreške grupirane su na razini općina.

* $p < 0,1$; ** $p < 0,05$; *** $p < 0,01$

Slika 10. Indeks cijena stambenih nekretnina i turizam



Napomena: Indeks cijena stambenih nekretnina službeni je tromjesečni indeks koji izračunavaju Hrvatska narodna banka i Državni zavod za statistiku. Indeks turističkih noćenja prikazuje dinamiku noćenja koju na godišnjoj razini iskazuje Državni zavod za statistiku.

Nadalje, turizam može utjecati na cijene stambenih nekretnina i kroz druge kanale osim broja turističkih noćenja. Kako Hrvatska postaje sve popularnija destinacija, moguće je da strani državljani s većom kupovnom moći sve više žele kupiti nekretninu u Hrvatskoj, čime se potiče rast cijena i/ili prelijeva njihov domaći ciklus cijena stambenih nekretnina na Hrvatsku. Istražujemo taj kanal analizom udjela transakcija inozemnih kupaca u svim transakcijama. Slika 11. pokazuje da je udjel transakcija inozemnih kupaca prilično stabilan cijelo vrijeme, s fluktuacijom na otprilike 10% od ukupnog broja transakcija – od 2018. taj broj zapravo pada.


Naposljetku, slijedeći sličnu argumentaciju, uz široko rasprostranjenu praksu iznajmljivanja privatnih stambenih nekretnina za turizam, moguće je da pojedinci iz priobalnih krajeva zarade dovoljno za kupnju stambenih nekretnina diljem Hrvatske, te time potiču rast njihovih cijena.¹⁹ Tako na primjer osoba iz Splita, nakon uspješne turističke sezone, može kupiti stan u Zagrebu. S obzirom na to da nam je poznata općina u kojoj se odvija transakcija i općina u kojoj kupac ima prebivalište, možemo ispitati je li ta dinamika značajna. Radi preglednosti podijelili smo 556 općina i gradova u tri skupine: priobalje, Zagreb i ostalo (vidi podjelu na Slici 2. u [Kunovac i Kotarac, 2019.](#))


¹⁹ U 2018. Hrvatska je među zemljama EU-a imala drugi najveći udjel (61,3%) kreveta izvan hotelskih kapaciteta i kapaciteta u kampovima, vidi Eurostat (2020.c).

te smo iz analize isključili inozemne kupce jer nas zanima dinamika unutar Hrvatske. Prikazujemo vremensku seriju udjela kupnje u devet kombinacija – tri lokacije gdje se odvija transakcija i tri lokacije prebivališta kupca – kako bismo vidjeli postoji li opaziva promjena u vrijeme uvođenja subvencioniranja stambenih kredita; rezultati su prikazani na Slici 12. Iako ova analiza nije sveobuhvatna jer, primjerice, osoba može imati prebivalište u Zagrebu i imati stanove u Splitu i kupovati stanove u Zagrebu nakon turističke sezone, možemo vidjeti da se ništa značajno nije dogodilo u vrijeme uvođenja subvencioniranja stambenih kredita.

Ove dodatne analize služe kako bi se uzeli u obzir ostali važni čimbenici tržišta nekretnina, i naši osnovni zaključci stoje. Ipak, tvrdimo da turizam u Hrvatskoj stvara trajan pritisak na tržište nekretnina u Hrvatskoj, što ga čini njegovom važnom odrednicom. Koristeći se objašnjenjima Hilbera i Turnera (2014.), koji pokazuju da će porast cijena nekretnina biti veći u područjima gdje je stambena ponuda neelastičnija, smatramo da turizam sustavno apsorbira stambene nekretnine, čime se smanjuje ponuda stambenih objekata. Drugim riječima, držimo da je turizam glavni pokretač neelastičnosti ponude stambenih nekretnina, stoga uzrokuje kapitalizaciju subvencioniranih stambenih kredita u obliku rasta cijena nekretnina.

Slika 11. Transakcije s domaćim i inozemnim kupcima (stanovi i kuće)



Slika 12. Stambene transakcije prema lokaciji transakcije i lokaciji kupca

Napomena: Svaki panel prikazuje udio transakcija različitih lokacija kupca (priobalje, ostalo i Zagreb, isključujući inozemne kupce) u ukupnom broju transakcija na određenoj lokaciji (priobalje, ostalo i Zagreb). Stoga zbroj udjela iz stupaca mora biti jedan. Na primjer, panel (1, 3) prikazuje dinamiku udjela kupaca iz općina u priobalju u transakcijama koje se odvijaju u Zagrebu.

3.4. Analiza geografskog diskontinuiteta intenziteta subvencioniranja stambenih kredita

Uvođenje diferenciranog pokrivanja anuiteta ovisno o općini u 2018. i 2019. (vidi Sliku 2.) omogućuje nam primjenu geografskih granica kao diskontinuiteta kako bismo istražili jesu li različite potencijalne subvencije različito djelovale na cijene stambenih nekretnina. Pitanju utjecaja intenziteta subvencija moglo bi se pristupiti iz različitih empirijskih perspektiva, npr. jedinstvenim modelom koji uključuje cijelu Hrvatsku. Međutim, tim bi se modelom zanemarili idiosinkratski prostorni obrasci i njihov međuodnos s tržištem nekretnina. Na primjer, učinak subvencioniranja stambenih kredita u Zagrebu mogao bi biti znatno različit od onog u Lici jer Zagreb ionako ima jaku gospodarsku i nekretninsku aktivnost.


Stoga odabiremo pristup u kojem rabimo samo poduzorak podataka kako bismo usporedili transakcije oko granice na kojoj se iznos subvencije stambenih kredita mijenja. Ako je raspon oko granice dovoljno uzak i uspoređuju se transakcije koje

su na bliskim lokacijama, ali imaju različiti iznos subvencije, zaobilazimo problem idiosinkratskih prostornih obrazaca i procjenjujemo uzročno-posljedični utjecaj. Kako svakoj nekretninskoj transakciji možemo pripisati katastarsku općinu (3368 lokacija, vidi Sliku 18. u Dodatku), procjenu lokacije transakcije dobivamo računanjem centra katastarske općine. Karta lokacija transakcija uz potencijalne subvencije prikazana je na Slici 13. S pomoću tih lokacija možemo pronaći *parove* transakcija i, j , gdje $i \neq j$, koje ispunjavaju tri uvjeta:


- obje transakcije u paru izvršene su u istom mjesecu
- lokacije transakcija u paru blizu su jedna drugoj, tj. nalaze se u rasponu od 10 km
- transakcije iz para imaju različite implicirane subvencije stambenih kredita. Lokacije koje pripadaju takvim parovima prikazane su na Slici 14.

Slika 13. Potencijalno subvencioniranje stambenih kredita u 2018. i 2019. i broj prodanih jedinica (2015. – 2019.).

a) Stanovi



b) Kuće



S pomoću bilateralnih parova transakcija ispitujemo mijenja li se tijekom vremena razlika u cijenama transakcija na bliskim lokacijama s različitim potencijalnim subvencioniranjem. Koristeći se podacima o bilateralnim parovima transakcija i, j , procjenjujemo proširenu jednadžbu 1:


$$d(\ln(cijena_i), \ln(cijena_j)) = \sum_{k=1}^T \delta_k D_{ik} D_{jk} d(sub_i, sub_j) + \alpha d(X_i, X_j) + \sum_{l=1}^L \beta_l loc_{il} + \sum_{m=1}^L \gamma_m loc_{im} + \epsilon_{ij} \quad (3)$$

gdje je $d(\cdot)$ standardna euklidska udaljenost, $d(\ln(cijena_i), \ln(cijena_j))$ apsolutna je vrijednost razlike u logaritmu cijena po kvadratnom metru stambenih jedinica i i j , $d(sub_i, sub_j)$ apsolutna je vrijednost razlike u potencijalnim subvencijama, $d(X_i, X_j)$ udaljenosti su između objašnjavajućih varijabla (veličina, starost i stanje stambene jedinice), a β_l -s i γ_m -s fiksni utjecaji lokacije (općine). Parametri δ_k -s označuju vremenski učinak razlike u implicitnoj subvenciji za par i i j na razliku u cijenama. U suštini ispitujemo mijenjaju li se δ_k -i pri uvođenju diferencirane subvencije u listopadu 2018.

Slika 14. Lokacije uzoraka u graničnom području, u radijusu od 10 km


a) Stanovi

Radijus od 10 km



b) Kuće


Radijus od 10 km




Ovaj nam pristup omogućuje da ispitamo je li uvođenje različite subvencije prema općini u 2018. i 2019. promijenilo razliku u cijenama unutar para nekretnina. Vremenski parametar te razlike prikazan je na Slici 15., a budući da je ta razlika stabilna tijekom vremena, možemo zaključiti da *intenzitet* subvencioniranja stambenih kredita ne utječe na cijene. Drugim riječima, iako je uvođenje subvencioniranja stambenih kredita potaknulo povećanu potražnju i pridonijelo ukupnom povećanju cijena stambenih nekretnina, uvođenje različitih subvencija stambenih kredita nije utjecalo na cijene u manje razvijenim područjima. Ovi rezultati zajednički pokazuju da je povećanje cijena stambenih nekretnina bilo u bogatijim područjima s ionako aktivnijim tržištem stambenih nekretnina i da slabije razvijena područja nisu zabilježila cjenovnu distorziju. To nas dovodi do intuitivnog zaključka iz kojeg se može izvesti izravna preporuka glede javne politike, a to je da subvencioniranje dovodi do veće distorzije cijena u područjima s aktivnijim tržištem stambenih nekretnina.

Slika 15. Rezultati studije događaja za granični uzorak (u radijusu od 10 km)

a) Stanovi



b) Kuće



Napomena: Podaci prikazuju rezultate bilateralnih parova skupine podataka o transakciji. Točke prikazuju procjene vremenskih učinaka uz razliku u implicitnoj potencijalnoj subvenciji (u odnosu na siječanj 2015.), a stupci prikazuju 99%-tne intervale pouzdanosti zasnovane na standardnim pogreškama grupiranim na razini općina. Kontrolne varijable uključuju razliku u veličini stambenih nekretnina, godini izgradnje i fiksnom učinku općine za obje transakcije u paru. Crveni stupci prikazuju utjecaje značajne na 99%-tnoj razini.

4. Zaključci

U radu istražujemo je li subvencioniranje stambenih kredita, uvedeno u Hrvatskoj u 2017., pridonijelo ukupnom povećanju cijena nekretnina. Subvencija koja je uvedena radi lakše kupnje stambenih nekretnina pokriva dio anuiteta u početnom razdoblju otplate stambenoga kredita, a specifičnost je programa da kućanstva mogu podnijeti zahtjev za subvenciju samo u kratkom vremenskom roku. U radu implicitno istražujemo učinkovitost ove mjere – ako su subvencije potaknule rast cijena stambenih nekretnina, kupci koji kupuju prvu stambenu nekretninu, a na koje se subvencija odnosi, suočavaju se s neučinkovitom mjerom, koja je u velikoj mjeri neutralizirana inflacijom cijena. Nadalje, porast cijena stambenih nekretnina također znači da će osobe koje kupuju stambenu nekretninu, a koje se ne koriste subvencijom, plaćati više cijene, čime stambene nekretnine postaju nepristupačnije. U radu iznosimo indikativne empirijske dokaze o tome da su subvencionirani stambeni krediti zaista pridonijeli ukupnom povećanju cijena nekretnina. Naši su rezultati robusni kroz različite specifikacije, pristupe i dodatne analize. Pokazujemo da su subvencije stambenih kredita, suprotno od njihove deklarirane namjene, učinile stambene nekretnine manje dostupnima, posebno kupcima koji se ne koriste subvencijama. Međutim, za obuhvatniju karakterizaciju programa potrebno je provesti dodatne analize. Na primjer, mogao bi se detaljnije analizirati međunarodni ciklus stambenih nekretnina ili detaljnije istražiti utjecaj turizma na cijene nekretnina. Također, detaljni podaci o osobama koje se koriste i onima koje se ne koriste subvencijama omogućili bi analizu mrtvog tereta programa te analizu demografskih i migracijskih aspekata i ciljeva programa.

5. Literatura

- Andrews, D., Caldera, A. i Johansson, Å. (2011.): *Housing markets and structural policies in OECD countries*, Technical report, OECD Publishing
- Andrews, D. i Sánchez, A. C. (2011.): *The evolution of homeownership rates in selected OECD countries: Demographic and public policy influences*, OECD Journal, Economic Studies, 2011.(1), str. 1 – 37
- Apgar, W. C. (2004.): *Rethinking rental housing: Expanding the ability of rental housing to serve as a pathway to economic and social opportunity*, Joint Center for Housing Studies, Graduate School of Design [i] John F. Kennedy School of Government, Harvard University
- APN (pristupljeno 1. srpnja, 2020.a): *Provedba subvencioniranja stambenih kredita za zahtjeve zaprimljene u 2017. god.*, <https://bit.ly/3fw3Vk9>
- APN (pristupljeno 1. srpnja, 2020.b): *Provedba subvencioniranja stambenih kredita za zahtjeve zaprimljene u 2018. god.*, <https://bit.ly/2SLvyvS>
- APN (pristupljeno 1. srpnja, 2020.c): *Subvencionirani stambeni krediti: Novosti*, <http://apn.hr/subvencionirani-stambeni-krediti/novosti>
- Caldera, A. i Andrews, D. (2011.): *To move or not to move: What drives residential mobility rates in the OECD?*, Technical report, OECD Publishing
- Christiano, L. i Fitzgerald, T. (2003.): *The band pass filter*, International Economic Review, 44(2), str. 435 – 465
- CNB (2019.): *Financijska stabilnost*, Tehničko izvješće br. 20, Hrvatska narodna banka, Hrvatska
- Comin, D. i Gertler, M. (2006.): *Medium-term business cycles*, American Economic Review, 96(3), str. 523 – 551
- Dietz, R. D. i Haurin, D. R. (2003.): *The social and private micro-level consequences of homeownership*, Journal of urban Economics, 54(3), str. 401 – 450
- DiPasquale, D. i Glaeser, E. L. (1999.): *Incentives and social capital: Are homeowners better citizens?* Journal of Urban Economics, 2(45), str. 354 – 384
- Drehmann, M., Borio, C. E. i Tsatsaronis, K. (2012.): *Characterising the financial cycle: Don't lose sight of the medium term!*, Technical report, BIS Working Papers 380
- Eurostat (pristupljeno 1. srpnja, 2020.a): *Distribution of population by tenure status*,

type of household and income group – EU-SILC survey, https://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=ilc_lvho02&lang=en

Eurostat (pristupljeno 1. srpnja, 2020.b): *Nights spent at tourist accommodation establishments – monthly data*, https://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=tour_occ_nim&lang=en

Eurostat (pristupljeno 1. srpnja, 2020.c): *Number of establishments, bedrooms and bed-places*, https://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=tour_cap_nat&lang=en

Haurin, D. R., Parcel, T. L. i Haurin, R. J. (2002.): *Does homeownership affect child outcomes?* Real Estate Economics, 30(4), str. 635 – 666

Hilber, C. A. i Turner, T. M. (2014.): *The mortgage interest deduction and its impact on homeownership decisions*, Review of Economics and Statistics, 96(4): str. 618 – 637

Hu, F. (2013.): *Homeownership and subjective wellbeing in urban China: Does owning a house make you happier?*, Social Indicators Research, 110(3), str. 951 – 971

Kreitmeyer, I. (2009.): *Studija tržišta nekretnina u Republici Hrvatskoj*, Technical report, Ministarstvo pravosuđa, Državna geodetska uprava

Kunovac, D. i Kotarac, K. (2019.): *Cijene stambenih nekretnina u Hrvatskoj*, Tehničko izvješće, Hrvatska narodna banka, Hrvatska

Kunovac, D., Mandler, M. i Scharnagl, M. (2018.): *Financial cycles in euro area economies: A cross-country perspective*, Technical report, Deutsche Bundesbank Discussion Paper 04/18

Lubell, J. (2014.): *Filling the void between homeownership and rental housing: a case for expanding the use of shared equity homeownership*, Homeownership Built to Last

Rappoport, D. (2016.): *Do mortgage subsidies help or hurt borrowers?*, Technical report, Board of Governors of the Federal Reserve System (SAD)

Rašić, I., Slijepčević, S., Stojčić, N. i Vizek, M. (2019.): *Pregled tržišta nekretnina Republike Hrvatske 2018.*, tehničko izvješće, Ekonomski institut, Zagreb

Rünstler, G., Balfoussia, H., Burlon, L., Buss, G., Comunale, M., De Backer, B., Dewachter, H., Guarda, P., Haavio, M. i Hindrayanto, I. *et al.* (2018.): *Real and financial cycles in EU countries: Stylised facts and modelling implications*, Technical report, Occasional Paper Series 205, Europska središnja banka

Rünstler, G. i Vlekke, M. (2018.): *Business, housing, and credit cycles*, Journal of Applied Econometrics, 33(2), str. 212 – 226

Sommer, K. i Sullivan, P. (2018.): *Implications of us tax policy for house prices, rents, and homeownership*, American Economic Review, 108(2), str. 241 – 274

Tkalec, M., Vizek, M. i Žilić, I. (2018.): *Pregled tržišta nekretnina Republike Hrvatske 2012. – 2017.*, tehničko izvješće, Ekonomski institut, Zagreb

Vansteenkiste, I. i Hiebert, P. (2011.): *Do house price developments spillover across euro area countries? Evidence from a global VAR*, Journal of Housing Economics, 20(4), str. 299 – 314

6. Dodatak

Tablica 3. Rezultati analize studije događaja

	Stanovi		Kuće	
	Koeficijent	Standardna pogreška	Koeficijent	Standardna pogreška
Vremenski učinci (odnosi se na 2015/01)				
2015/02	0,004	(0,014)	0,090	(0,095)
2015/03	0,0003	(0,015)	0,008	(0,096)
2015/04	-0,009	(0,017)	0,003	(0,100)
2015/05	-0,003	(0,015)	-0,020	(0,098)
2015/06	-0,004	(0,019)	0,078	(0,112)
2015/07	-0,031*	(0,016)	-0,020	(0,094)
2015/08	-0,011	(0,022)	0,026	(0,101)
2015/09	-0,010	(0,017)	-0,019	(0,098)
2015/10	-0,020	(0,016)	0,014	(0,096)
2015/11	-0,025	(0,015)	-0,080	(0,115)
2015/12	-0,030**	(0,014)	0,069	(0,108)
2016/01	0,0002	(0,018)	-0,058	(0,112)
2016/02	0,002	(0,019)	-0,054	(0,097)
2016/03	-0,007	(0,014)	0,141	(0,103)
2016/04	-0,020	(0,023)	-0,035	(0,093)
2016/05	-0,005	(0,022)	-0,022	(0,125)
2016/06	-0,002	(0,016)	-0,068	(0,099)
2016/07	-0,017	(0,027)	0,030	(0,100)
2016/08	-0,006	(0,020)	-0,051	(0,095)
2016/09	0,014	(0,018)	-0,143	(0,108)
2016/10	-0,020	(0,016)	-0,038	(0,108)
2016/11	-0,017	(0,019)	-0,125	(0,110)
2016/12	0,008	(0,014)	-0,002	(0,105)
2017/01	-0,0005	(0,019)	0,014	(0,115)
2017/02	-0,011	(0,026)	0,044	(0,103)
2017/03	-0,031	(0,031)	0,057	(0,095)
2017/04	-0,044	(0,054)	-0,073	(0,113)
2017/05	-0,002	(0,040)	0,006	(0,093)
2017/06	0,014	(0,023)	-0,018	(0,103)
2017/07	0,007	(0,023)	0,062	(0,103)
2017/08	0,030	(0,023)	0,067	(0,103)
2017/09	0,022	(0,030)	0,124	(0,093)
2017/10	0,060***	(0,021)	0,235***	(0,091)
2017/11	0,082***	(0,023)	0,226**	(0,094)
2017/12	0,085***	(0,025)	0,174	(0,108)


2018/01	0,017	(0,018)	0,058	(0,110)
2018/02	0,046*	(0,025)	0,064	(0,099)
2018/03	0,050*	(0,027)	0,085	(0,097)
2018/04	0,024	(0,019)	0,019	(0,102)
2018/05	0,048**	(0,023)	0,165*	(0,098)
2018/06	0,017	(0,025)	0,141	(0,102)
2018/07	0,041	(0,026)	0,143	(0,091)
2018/08	0,071**	(0,034)	0,004	(0,099)
2018/09	0,081***	(0,021)	0,152	(0,093)
2018/10	0,068***	(0,021)	0,124	(0,102)
2018/11	0,070***	(0,019)	0,173*	(0,101)
2018/12	0,048**	(0,022)	0,065	(0,110)
2019/01	0,102***	(0,034)	0,098	(0,096)
2019/02	0,099***	(0,028)	0,122	(0,106)
2019/03	0,102***	(0,031)	0,094	(0,100)
2019/04	0,112***	(0,030)	0,075	(0,100)
2019/05	0,136***	(0,037)	0,131	(0,098)
2019/06	0,125***	(0,030)	0,163	(0,103)
2019/07	0,119***	(0,036)	0,164*	(0,087)
2019/08	0,107***	(0,037)	0,073	(0,095)
2019/09	0,130**	(0,051)	0,092	(0,094)
2019/10	0,147***	(0,029)	0,182**	(0,091)
2019/11	0,157***	(0,035)	0,234**	(0,111)
2019/12	0,156***	(0,030)	0,274**	(0,110)
Deset indikatorskih varijabla za veličinu	Da		Da	
Deset indikatorskih varijabla za starost	Da		Da	
Tri indikatorske varijable za stanje	Da		Da	
Indikatorske varijable za inozemnog kupca i prodavatelja	Da		Da	
Fiksni učinci općina	Da		Da	
Opažanja	79.026		12.078	
Prilagođeni R ²	0,466		0,500	
Rezidualna standardna pogreška	0,297		0,703	

Napomena: Standardne su pogreške na razini općina.


p<0,1; **p<0,05; *p<0,01*

Slika 16. Studija događaja zasnovana na indeksu razvijenosti

a) Stanovi




b) Kuće




Bilješka: Točke prikazuju procjene vremenskih učinaka ($\exp(\delta_k) \times 100$; u odnosu na siječanj 2015.), a stupci predstavljaju 99%-tne intervale pouzdanosti na temelju standardnih pogrešaka grupiranih na razini općina. Kontrolne varijable uključuju deset skupina indikatorskih varijabla za veličinu, deset skupina indikatorskih varijabla za godinu izgradnje (nedostajuće vrijednosti kodirane su kao posebna skupina i uključene u specifikaciju), tri skupine indikatorskih varijabla za stanje stambene nekretnine (nedostajuće vrijednosti kodirane su kao posebna skupina i uključene u specifikaciju), pokazatelje koji se odnose na inozemnog kupca i prodavatelja i fiksni utjecaj općina i broj turističkih noćenja na razini općine. Crveni stupci prikazuju utjecaje značajne na 99%-tnoj razini.

Slika 17. Cijene stanova u 2015. i 2016.


a) Gradijent cijene i veličine



b) Gradijent godine izgradnje i cijene po m²



Napomena: Crvene crte prikazuju procjenu lokalne linearne regresije y na x.

Slika 18. Katastarske općine i potencijalne subvencije u 2018.

Tablica 4. Opis procijenjenih modela

Procijenjeni model	Učestalost podataka	Nezavisne varijable	Veličina uzorka	Rezultati u radu
Hedonistička regresija	Podaci o pojedinačnim stambenim transakcijama s vremenskim učincima na razini mjeseca	Deset skupina indikatorskih varijabla za veličinu stambene nekretnine, deset skupina indikatorskih varijabla za godinu izgradnje (nedostajuće vrijednosti kodirane su kao posebna skupina i uključene u specifikaciju), tri skupine indikatorskih varijabla za stanje stambene nekretnine (nedostajuće vrijednosti kodirane su kao posebna skupina i uključene u specifikaciju), pokazatelji koji se odnose na inozemnog kupca i prodavatelja i fiksni utjecaj općine	79.026 za stanove i 12.078 za kuće	Slika 5. i Tablica 3.
Hedonistička regresija, heterogeni utjecaji ovisno o županiji, veličini, godini izgradnje i indeksu razvijenosti	Pojedinačni podaci o stambenim transakcijama s vremenskim učincima na razini mjeseca	Kao i u osnovnoj hedonističkoj regresiji, ali bez varijable na kojoj se zasniva skupina	79.026 za stanove i 12.078 za kuće	Slika 6. (županija), Slika 7.a) (veličina), Slika 7.b) (godina izgradnje), Slika 16. (indeks razvijenosti)
Analiza glavnih sastavnica ciklusa cijena stambenih nekretnina poslovnom i financijskom učestalošću	Tromjesečni podaci o cijenama stambenih nekretnina u 20 europskih zemalja od 1. tr. 2008. do 4. tr. 2019.	–	48 opažanja za svaku od 20 zemalja	Slika 8.
Hedonistička regresija s varijablama koje uzimaju u obzir turizam	Pojedinačni podaci o stambenim transakcijama s vremenskim učincima na razini godine	Kao i u osnovnoj hedonističkoj regresiji uz dodatak godišnje potrošnje po turističkim noćenjima po glavi stanovnika za svaku općinu	79.001 za stanove i 11.656 za kuće	Slika 9. i Tablica 2.
Hedonistička regresija na graničnom uzorku	Par pojedinačnih stambenih transakcija koje se odvijaju u istom mjesecu, manje od 10 km fizički su udaljene jedna od druge i imaju različite implicitne subvencije zbog indeksa razvijenosti. Utjecaji vremena procijenjeni su s pomoću vremenskih učinaka na razini mjeseca.	Euklidska udaljenost među transakcijama, u cijenama po kvadratnom metru, potencijalne subvencije, veličina, starost, stanje stambene jedinice i fiksni utjecaji općine za svaku transakciju	33.631 za stanove i 3.374 za kuće	Slika 15.

IZDAVAČ

Hrvatska narodna banka
Trg hrvatskih velikana 3
10000 Zagreb
T. +385 1 4564 555
www.hnb.hr

GLAVNI UREDNIK

Ljubinko Jankov

UREDNIŠTVO

Vedran Šošić
Gordi Sušić
Davor Kunovac
Maroje Lang
Davor Galinec
Maja Bukovšak
Dražen Odorčić
Boris Cota
Tomislav Ridzak
Evan Kraft
Ante Žigman

IZVRŠNI UREDNIK

Katja Gattin Turkalj

LEKTORICA

Dragica Platužić

DIZAJNER

Vjekoslav Gjergja

GRAFIČKI UREDNIK

Božidar Bengez

Za stajališta iznesena u ovom radu odgovorni su autori i ta stajališta nisu nužno istovjetna službenim stajalištima Hrvatske narodne banke.

Molimo korisnike ove publikacije da pri korištenju podataka obvezno navedu izvor.

ISSN 1334-0077 (online)

**Dome, slatki dome: učinak subvencioniranja stambenih kredita
na tržište nekretnina u Hrvatskoj**

ISSN 1234-5678 (online)

