

*Jakša Puljiz**
*Ivana Rukavina***

JEL klasifikacija: C21, O18, R11, R15
 Izvorni znanstveni rad
<https://doi.org/10.32910/ep.73.5.2>

ANALIZA KONVERGENCIJSKOG PROCESA NA LOKALNOJ I REGIONALNOJ RAZINI U HRVATSKOJ

Koristeći se podacima o osobnim dohocima u radu se analizira proces konvergencije na lokalnoj i županijskoj razini u Republici Hrvatskoj u razdoblju 2002. – 2018. pomoću koncepta sigma i beta konvergencije. Također, u radu se testira mobilnost lokalnih i županijskih jedinica u promatranom razdoblju korištenjem matrice prijelaznih vjerojatnosti temeljene na Markovljevom lancu. Rezultati provedenog istraživanja ukazuju na smanjenje dohodovnih nejednakosti na lokalnoj i županijskoj razini te na prisutnost apsolutne i uvjetne beta konvergencije. Dalnjom analizom utvrđeno je da konvergencija izrazito jača nakon 2014. godine. Rezultati matrice prijelaznih vjerojatnosti sugeriraju da se proces konvergencije odvija, prije svega, kroz promjene u srednjem dijelu distribucije teritorijalnih jedinica, što znači da najsirošnije lokalne i županijske jedinice i dalje imaju vrlo male šanse za promjenu svojega relativnog položaja.

Ključne riječi: regionalne nejednakosti, konvergencija, osobni dohoci, Hrvatska

* J. Puljiz, dr. sc., Institut za razvoj i međunarodne odnose (IRMO), Zagreb, viši znanstveni suradnik, (e-mail: jpuljiz@irmo.hr).

** I. Rukavina, dr. sc., (e-mail: irukavina01@gmail.com). Rad je primljen u uredništvo 04.01.2021. godine, a prihvaćen je za objavu 26.11.2021. godine.

1. UVOD

Hrvatska se obično percipira kao zemlja sa značajnim regionalnim razlikama. Do takvog se zaključka uglavnom dolazi analizom podataka o bruto domaćem proizvodu po stanovniku na županijskoj razini, koja je najniža subnacionalna razina za koju su dostupni podaci o bruto domaćem proizvodu (BDP). Tako, primjerice, podaci Državnog zavoda za statistiku za 2017. pokazuju kako je BDP po stanovniku grada Zagreba, kao najrazvijenije jedinice, 3,2 puta veći od BDP-a Virovitičko-podravske županije, koja je najmanje razvijena županija. Iz navedenoga se intuitivno može zaključiti kako su regionalne razlike značajne.¹ Usporedba s drugim novim članicama Europske unije (EU) pokazuje kako Hrvatska nije izuzetak jer većina novih država članica također bilježi značajne regionalne razlike, koje su, uglavnom, čak i veće nego u Hrvatskoj (Mikulić, Lovrinčević i Galić Nagyszombaty, 2013.).

Osim visine regionalnih razlika, posebno je važno i pitanje o dinamici razlika, odnosno da li se one s vremenom smanjuju, stagniraju ili rastu. Osnovni uvjet za smanjenje regionalnih razlika je proces konvergencije, tj. sustizanja razvijenijih jedinica od strane slabije razvijenih, što bi potonje trebale ostvariti postizanjem većih stopa gospodarskog rasta. Ekonomski teorija pruža različite mogućnosti putanje regionalnih razlika, ovisno o tome koji se modeli rasta uzimaju u obzir. Brojni empirijski radovi na temu konvergencije donose različite zaključke o smjeru i dinamici regionalnih razlika, čak i kad je riječ o istoj grupi teritorijalnih jedinica poput, primjerice, regija u Europskoj uniji. Razlike u rezultatima javljaju se, između ostalog, zbog različitih pristupa mjerjenju konvergencije, a različiti pristupi su pak rezultat različitih teorijskih koncepata povezanih s pitanjem konvergencije. Dok je teorijska i empirijska literatura koja se bavi pitanjem konvergencije na razini regija vrlo obimna, relativno mali broj radova bavi se pitanjem konvergencije na lokalnoj razini.² To se može objasniti nedostatkom odgovarajućih podataka na lokalnoj razini, a prije svega podataka o bruto domaćem proizvodu (BDP) po stanovniku koji se obično uzima kao standardni pokazatelj razvijenosti teritorijalnih jedinica. U ovom se radu stoga koriste podaci o osobnim dohodima stanovnika, a koji su dostupni na županijskoj i na lokalnoj razini. Glavni cilj rada je analizom dinamike osobnih dohodaka po stanovniku na županijskoj i lokalnoj razini, steći dublji uvid u proces konvergencije na subnacionalnoj razini u Hrvatskoj. Korištenje podataka o osobnim dohodima za razdoblje 2002. – 2018. omogućilo je provedbu analize

¹ Tu se odmah može postaviti pitanje koliko je zapravo validna usporedba jednog dominantno urbanog s pretežno ruralnim područjem, te se u tom pogledu čini primjerenojim uspoređivati BDP po stanovniku Zagreba sa Splitom, Rijekom i Osijekom (kada bi ti podaci bili dostupni).

² U slučaju Hrvatske dinamika rasta i regionalnih razlika na lokalnoj razini je bila predmet istraživanja kod Puljiz, Maleković (2007)

tijekom relativno duljeg vremenskog razdoblja. Analizom je ispitana i potvrđena prisutnost konvergencijskog procesa na županijskoj kao i na lokalnoj razini kad je riječ o osobnim dohocima. Pored toga analiza je prepoznala i nekoliko važnih čimbenika koji su povezani s procesom konvergencije. Konačno, rezultati su ukazali na problem kvalitete konvergencijskog procesa budući da dio najsiromašnijih jedinica nije uspio poboljšati svoj relativan položaj.

Nastavak rada organiziran je kako slijedi: drugo poglavlje donosi pregled relevantne teorijske i empirijske literature, u trećem poglavlju predstavljeni su metodologija i podaci korišteni za analizu, rezultati empirijskog testiranja prikazani su u četvrtom poglavlju, dok su zaključci izneseni u petom poglavlju.

2. PREGLED LITERATURE

Literatura na temu konvergencije obično razlikuje dvije osnovne vrste konvergencije: *beta* i *sigma* konvergenciju. *Beta* konvergencija podrazumijeva proces u kojem zemlje/regije s nižim stupnjem dohotka po stanovniku rastu po višoj stopi od zemalja/regija s višim stupnjem dohotka po stanovniku, te ih stoga i sustižu u razvijenosti, odnosno događa se konvergencija. *Sigma* konvergencija podrazumijeva da se disperzija gospodarstava prema stupnju razvijenosti s vremenom smanjuje. Između ova dva osnovna koncepta konvergencije, postoji međusobni odnos: *beta* konvergencija je nužan, ali ne i dovoljan preduvjet za postizanje *sigma* konvergencije.

Koncept beta konvergencije temelji se na neoklasičnoj teoriji rasta (Solow, 1956) prema kojoj zemlje/regije s nižim dohotkom po stanovniku ostvaruju veće stope rasta od zemalja s većim dohotkom po stanovniku zbog zakona opadajućih prinosa, koji vrijedi za kapital kao faktor proizvodnje. Uz pretpostavku da sve ekonomije konvergiraju prema istoj ravnotežnoj stopi rasta, bez obzira na njihova druga obilježja, govorimo o prisustvu absolutne konvergencije. Međutim, empirijska istraživanja pokazala su da je u velikom broju slučajeva konvergencija uvjetovana specifičnim obilježjima koji utječu na stope rasta, a koja se mogu razlikovati između pojedinih država odnosno regija kao što su, primjerice, kvaliteta institucija, dostupnost tehnologije, rast stanovništva i dr. Stoga se uvodi pojam uvjetne konvergencije prema kojoj države/regije, ako dijele neka ključna obilježja, konvergiraju dugoročno istoj ravnotežnoj stazi rasta.

Pored absolutne i uvjetne konvergencije, u literaturi se razrađuje i koncept tzv. klubova konvergencije. On podrazumijeva mogućnost da pojedine skupine zemalja/regija konvergiraju prema vlastitim stazama rasta, a koje se razlikuju od

staza neke druge skupine. Drugim riječima, dopušta se mogućnost postojanja više-strukih ravnotežnih staza rasta kojima konvergiraju pojedine skupine teritorijalnih jedinica. Tome su glavni razlog razlike u početnim uvjetima pojedinih jedinica (Chatterji, 1992, Durlauf, 1993, Quah, 1996). Klubovi konvergencije su povezani s velikim brojem različitih modela rasta koji omogućuju postojanje različitih staza rasta (za pregled literature vidjeti Azariadis, 1996).

Kad je riječ o empirijskim testiranjima konvergencije na regionalnoj razini, ona su postala osobito popularna nakon objavlјivanja radova čiji su autori Barro i Sala-i-Martin (1992) te Mankiw, Romer i Weil (1992). U njima se konvergencija testira korištenjem regresijskih jednadžbi vremenskog presjeka. U većini slučajeva zabilježena je prisutnost apsolutne konvergencije. Međutim, stope konvergencije značajno se razlikuju od zemlje do zemlje. Barro i Sala-i-Martin (2004) ističu kako se prisutnost apsolutne konvergencije na regionalnoj razini može lako objasniti većom homogenošću regija unutar zemlje s obzirom na tehnologiju, preferenciju potrošača i institucija, nego u slučaju različitih zemalja, zbog čega regije teže istim ili jako sličnim ravnotežnim stanjima, što je u skladu s pretpostavkama neoklasične teorije rasta. Nadalje, ustanovili su da je brzina kojom regije u ispitanim zemljama konvergiraju vrlo slična te iznosi oko 2 % godišnje, što bi značilo da je konvergencija jako spor proces.

Na tragu koncepta klubova konvergencije, Quah (1993, 1996) kritizira pristup testiranju Barroa i Sala-i-Martina te predlaže alternativni pristup koji se temelji na Markovljevu lancu. Njime se uzimaju u obzir cjelovite informacije o distribuciji dohodaka po stanovniku kako bi se ocijenile promjene u distribuciji tijekom vremena. Zemlje/regije dijele se u pojedine skupine ovisno o visini dohotka po stanovniku, te se vrši procjena vjerojatnosti prelaska zemlje/regije iz bilo koje skupine na početku mjerjenja u bilo koji razred na kraju razdoblja promatranja. Međutim, ni primjena Markovljeva lanca ne vodi jedinstvenim zaključcima o prisutnosti konvergencije. Tako López-Bazo i sur. (1999) analiziraju podatke o rastu regija u Europskoj uniji u razdoblju 1980. – 1992. i zaključuju kako postoji proces konvergencije u gornjem dijelu distribucije, odnosno kod razvijenijih regija, dok konvergencija izostaje kod slabije razvijenih regija. Slične rezultate o slaboj mobilnosti siromašnijih regija prema višim skupinama razvijenosti nalazi i Le Gallo (2004). S druge strane, Castro (2003) zaključuje kako postoji snažna konvergencija, odnosno mobilnost siromašnijih regija EU-a u razdoblju 1980. – 1996., slično kao i Magrini (1999).

Kad je riječ o istraživanjima regionalne konvergencije u europskim zemljama, brojna istraživanja koja su se odnosila na stare članice pokazala su prisutnost konvergencije. Istraživanja provedena za Španjolsku (de la Fuente, 2002), Veliku Britaniju (Chatterji i Dewhurst, 1996), Švedsku (Persson, 1997), Grčku (Siriopoulos i Asteriou, 1998), zapadni dio Njemačke (Niebuhr, 2001) i Austriju (Hofer and

Wörgötter, 1997.) većinom potvrđuju prisutnost apsolutne konvergencije, ali same stope konvergencije značajno se razlikuju od zemlje do zemlje. Neka istraživanja poput onog koji su proveli Arbia, Basile i Salvatore (2003) pokazuju kako je regionalna konvergencija u Italiji snažno povezana s prostornim čimbenicima poput prostorne korelacije i efekata prelijevanja na susjedne regije. Autori dokazuju kako je bez uključivanja ovih prostornih čimbenika stvarna brzina konvergencije znatno podcijenjena. Testiranje prisutnosti *sigma* i *beta* konvergencije u Portugalu na NUTS 3³ (engl. Nomenclature of territorial units for statistics) razini u razdoblju 1991. – 2000. ukazuje na blago smanjenje regionalnih nejednakosti na NUTS 3 razini. Međutim, rezultati testiranja *beta* konvergencije više idu u prilog argumentu uvjetne konvergencije, regije više konvergiraju prema vlastitoj ravnotežnoj stazi nego prema zajedničkoj (Soukiazis, Antunes, 2004). Lopes, Araujo (2016) na primjeru regija u Portugalu i Španjolskoj (81 NUTS 3 jedinica) ukazuju na prisutnost *sigma* konvergencije u razdoblju 1995. – 2012., s tim da se divergencija bilježi do 2001. godine, a konvergencija nakon toga. Također, veća disperzija bilježi se u Portugalu nego u Španjolskoj. Rezultati također potvrđuju prisutnost *beta* konvergencije.

Kad je riječ o novim zemljama članicama, većina istraživanja pokazuje prisutnost procesa divergencije. Petrakos, Psycharis i Kallioras (2005) analiziraju regionalne razlike među zemljama kandidatima za ulazak u Europsku uniju prema BDP-u po stanovniku u razdoblju 1995. – 2000. Utvrđuju da je stupanj regionalnih razlika u razvijenosti kod svih zemalja kandidata sličan ili čak nešto veći od onog u starim članicama, što znači da su u relativno kratkom razdoblju zemlje kandidati zabilježile vrlo visok porast regionalnih razlika. Autori su također utvrdili kako proces konvergencije između starih i novih zemalja članica istovremeno prati proces divergencije unutar novih zemalja članica. Piętak (2015) analizira pokazatelje konvergencije BDP-a po stanovniku i stope zaposlenosti (od 2005. do 2011.) na primjeru poljskih regija te utvrđuje prisutnost rastućih regionalnih razlika, s tim da je porast nejednakosti posebno izražen počev od 2008., kad je započela snažna divergencija regionalnih stopa zaposlenosti. Istraživanje provedeno za regije u Rumunjskoj na NUTS 2 razini nije ukazalo na prisustvo konvergencije dohotka po stanovniku (Munteanu, 2015). Zaključak istraživanja, koje je pokrilo vremenski period od 1995. do 2011., bio je da se regionalne razlike u Rumunjskoj na NUTS 2 razini povećavaju. Chocholata i Furkova (2016) proveli su jedno od rijetkih istraživanja koje nije koristilo podatke o BDP-u, već podatke Eurostata o raspoloživom osobnom dohotku na NUTS 3 razini za šest srednjoeuropskih zemalja. Rezultati

³ NUTS klasifikacija je službena statistička klasifikacija Europske unije kojom se zemlje članice kao i njihove subnacionalne teritorijalne jedinice dijele na nekoliko razina. NUTS 2 razina obuhvaća regije čiji se broj stanovnika kreće između 3 i 7 milijuna, a NUTS 3 razina regije čiji se broj stanovnika kreće između 800.000 i 3 milijuna.

testiranja su pokazali da su, osim u slučaju Mađarske, kod svih drugih zemalja zabilježene stabilne regionalne razlike.

U Hrvatskoj se pitanju konvergencije uglavnom pristupalo na NUTS 3, županijskoj razini, koristeći podatke o BDP-u po stanovniku. Istraživanje koje je proveo Drezgić (2011) na uzorku od 20 županija (NUTS 3) u vremenskom razdoblju obilježenom gospodarskim rastom od 2000. do 2007., ukazalo je na izostanak konvergencije i povećanje regionalnih razlika prema bruto domaćem proizvodu po stanovniku, što se povezuje s utjecajem rastućih javnih investicija, posebno u cestogradnju, nakon 2002. godine. Mikulić i sur. (2013) sugeriraju da u razdoblju od 2001. do 2008. u Hrvatskoj nije bila prisutna absolutna konvergencija BDP-a po stanovniku na županijskoj razini. Uključenje dodatnih varijabli u model uvjetne konvergencije također nije dokazalo prisutnost konvergencije. Mikulić, Galić Nagyszombaty (2015) su pokazali da je u razdoblju 2000. – 2011. bio prisutan proces konvergencije na županijskoj razini te da je međunarodna razmjena imala vrlo slab utjecaj na sam proces regionalnog rasta. Đokić, Fröhlich i Rašić Bakarić (2016) su pokazali da su se regionalne razlike mjerene BDP-om po stanovniku za vrijeme krize 2008. – 2012. povećale, a smanjile se prema stopi nezaposlenosti. Jedino istraživanje koje je do sada uključilo ocjenu nejednakosti na lokalnoj razini odnosilo se na razdoblje 2000. – 2005. (Puljiz, Maleković, 2007). Autori su ocjenjivali dinamiku nejednakosti prema osobnim dohocima i stopi nezaposlenosti između i unutar županija. Rezultati analize pokazali su kako je Hrvatska suočena sa značajnim porastom razlika prema oba pokazatelja te da sve više jača komponenta međužupanijskih razlika u odnosu na razlike unutar županija.

3. PODACI I METODOLOGIJA

Mjerenje konvergencije u ovom radu temelji se na podacima Porezne uprave o osobnim dohocima koji uključuju neto plaće i mirovine isplaćene tijekom jedne godine stanovnicima s prebivalištem na području pojedine županije, odnosno jedinice lokalne samouprave, što je na tragu pristupa koji su već ranije primijenili Puljiz i Maleković (2007).

Korištenje osobnih dohodata u odnosu na BDP (tamo gdje podaci postoje) ima nekoliko važnih prednosti. S jedne strane, podaci o osobnim dohocima omogućuju „spuštanje“ analize na lokalnu razinu, čime se dobiva dodatni i dublji uvid u razinu i dinamiku nejednakosti konvergencije na subnacionalnoj razini u Hrvatskoj. Nadalje, primjena analize na lokalnoj razini osigurava znatno veću statističku pouzdanost rezultata kod ekonometrijskog testiranja u odnosu na županijsku razinu, s obzirom na znatno veći broj opažanja koje donosi lokalna razina.

Također, kad je riječ o županijskoj razini, korištenjem osobnih dohodaka gubi se utjecaj dnevnih migracija zaposlenika na rezultate. Naime, BDP-u pojedine teritorijalne jedinice doprinose stanovnici koji dnevno putuju na posao iz neke druge jedinice. Stoga, što je takvih slučajeva više to je teže interpretirati nalaze analize u kontekstu ekonomskog blagostanja stanovnika. Podaci za lokalnu razinu odnose se na 540 lokalnih jedinica za koje su prikupljeni podaci u cijelom promatranom razdoblju od 2002. do 2018. godine.⁴

Za ocjenu prisutnosti *sigma* konvergencije dohotka koristi se tzv. Willamsonov indeks koji pri ocjeni disperzije uzima u obzir razlike u veličini broja stanovnika među teritorijalnim jedinicama te se, stoga, pokazao kao pouzdan pokazatelj u analizama regionalnih nejednakosti (Portnov, Felsenstein, 2005). Indeks se računa kao koeficijent varijacije ponderiran udjelom pojedine jedinice u ukupnoj populaciji:

$$CV_w = \frac{1}{\bar{y}} \sqrt{\left[\sum_{i=1}^n (y_i - \bar{y})^2 \frac{P_i}{P_{tot}} \right]} \quad (1)$$

gdje je y_i dohodak po stanovniku u jedinici i , \bar{y} nacionalni prosjek dohotka po stanovniku, P_i populacija u jedinici i , P_{tot} ukupna populacija, n broj regija.

Hipoteza apsolutne *beta* konvergencija koja podrazumijeva brži rast slabije razvijenih jedinica u usporedbi s više razvijenim jedinicama testirat će se temeljem sljedeće regresijske jednadžbe

$$T^{-1} \ln \left(\frac{y_{iT}}{y_{i0}} \right) = \alpha_0 + \beta_1 \ln(y_{i0}) + \varepsilon_i \quad (2)$$

Brzinu konvergencije koja mjeri koliko brzo teritorijalna jedinica konvergira prema ravnotežnom stanju označava se s b te se računa kao:

$$b = -\frac{\ln(1 + t\beta_1)}{t} \quad (3)$$

Dodatni pokazatelj u analizi konvergencije je pokazatelj pola života koji izražava vrijeme potrebno da pokriju polovicu početnog zaostajanja od svojeg ravnotežnog stanja, a koje se ostvaruje pri utvrđenoj razini konvergencije. Pokazatelj pola života poprima sljedeći oblik:

⁴ U Hrvatskoj ima 556 lokalnih jedinica. Međutim, dio lokalnih jedinica osnovan je nakon 2002. godine pa za njih nisu bili dostupni podaci za cijelo razdoblje. Također, izostavljene su vrijednosti za sve lokalne jedinice koje u prosjeku imaju manje od 500 stanovnika (referentni interval je 2002. – 2018.), jer kod dijela pokazatelja bilježe ekstremne vrijednosti koje onda znatno utječu na izračun parametara modela. U konačnici je analiza provedena nad 540 lokalnih jedinica.

$$\tau = \ln(2)/b \quad (4)$$

Prisutnost uvjetne *beta* konvergencije uobičajeno se testira sljedećim regresijskim modelom:

$$T^{-1} \ln\left(\frac{y_{iT}}{y_{i0}}\right) = \alpha_0 + \beta_1 \ln(y_{i0}) + \sum_{j=1}^n \gamma_j X_j + \varepsilon_i \quad (5)$$

$T^{-1} \ln\left(\frac{y_{iT}}{y_{i0}}\right)$ predstavlja prosječnu stopu rasta dohotka po stanovniku teritorijalne jedinice i (između završne godine i početne godine), $\ln(y_{i0})$ – logaritamska vrijednost dohotka po stanovniku teritorijalne jedinice i u početnoj godini, ε_i su greške relacije, a X_j – predstavlja vektor nezavisnih varijabli u modelu.

Za potrebe analize apsolutne i uvjetne *beta* konvergencije u radu se koristi regresijska analiza vremenskog presjeka (engl. *cross-sectional regression*) običnom metodom najmanjih kvadrata (OLS, engl. *ordinary least square*).⁵ OLS metoda ima jedan nedostatak, a to je da ne uzima u obzir razlike među prostornim jedinicama u pogledu broja stanovnika, što u određenim situacijama može dovesti do pogrešnih zaključaka. Zbog toga je u literaturi predložena alternativna procjena vaganom metodom najmanjih kvadrata (WLS, engl. *weighted least square*) (vidjeti npr. Cole, Neumayer, 2003., Petrakos, Kallioras i Anagnostou, 2011., Sorens, 2014.). Kad se analiziraju prostorne jedinice sa znatnim razlikama u broju stanovnika WLS procjenitelj smatra se efikasnijim, jer osigurava prostornim jedinicama utjecaj koji je analogan njihovoj relativnoj veličini prema broju stanovnika⁶. Stoga će se za potreba ove analize koristiti i OLS i WLS metoda⁷.

U oba slučaja zavisna varijabla izražena je kao prosječan godišnji rast dohotka po stanovniku ($T^{-1} \ln\left(\frac{y_{iT}}{y_{i0}}\right)$), a pojava negativnog predznaka parametra β_1 sugerira prisustvo *beta* konvergencije (Barro, Sala-i-Martin, 1992).

Pored početne razine osobnih dohodaka po stanovniku, kod modela uvjetne konvergencije testirane su sljedeće objašnjavajuće varijable koje su ocijenjene važnim strukturnim obilježjima jedinica na lokalnoj i županijskoj razini:

⁵ Premda se u literaturi vrlo često za konvergencijske analize koriste panel modeli, u ovom slučaju je to izostavljeno. Razlog je nedostatak dijela podataka za pojedine godine i pojedine lokalne jedinice koji, posljedično, dovode do problema nebalansiranih podataka, što nadalje umanjuje pouzdanost testiranja.

⁶ Detaljnije obrazloženje i primjena WLS metodologije u analizi konvergencije može se naći kod Petrakos, Artelaris (2009).

⁷ Za ponderiranje primjenom vagane metode koriste se podaci o prosječnoj populaciji u pojedinoj jedinici ovisno o razdoblju koje se analizira.

- obrazovanje – udio broja visokoobrazovanih osoba u populaciji u dobi od 20 – 64 godina prema rezultatima popisa stanovništva 2001. ili 2011. (oznaka OBRAZ)⁸
- kretanje broja stanovnika – stopa promjene broja stanovnika unutar promatrano razdoblja (oznaka STAN).
- turistička razvijenost – na lokalnoj se razini definira kao *dummy* varijabla pri čemu 1 predstavlja status obalne ili otočne lokalne jedinice, a na županijskoj razini definira se kao logaritam prosječnog broja noćenja na godišnjoj razini u promatranom razdoblju (oznaka TURIZAM)

Razina obrazovanja standardan je primjer objašnjavajuće varijable u modelima rasta. S druge strane, uvođenje promjena broja stanovnika kao varijable ima za cilj ocijeniti povezanost učinaka demografskih promjena i dinamike dohodaka, što se čini kao važna tema s obzirom na relevantnost demografskih pitanja za regionalni rast i razvoj. Slično tome, varijabla turistička razvijenost odražava snažnu ulogu koju sektor turizma ima u gospodarskom razvoju, prije svega primorskog dijela zemlje.

Kako bi se dodatno ocijenio utjecaj ekonomske krize iz 2009. i postkriznog oporavka, analiza apsolutne i uvjetne konvergencije provedena je za tri različita vremenska razdoblja: (i) cijelo razdoblje od 2002. do 2018.; ii) razdoblje od 2002. do 2008. koje predstavlja razdoblje prije početka globalne finansijske krize, odnosno gospodarske krize u Hrvatskoj te iii) razdoblje od 2009. do 2018. koji pokriva razdoblje krize (2009. – 2014.) te oporavak (2015. – 2018.).

Primjena Markovljevog lanca temelji se na izračunu tzv. matrice prijelaznih vjerojatnosti P koja se temelji na dohodovnim skupinama teritorijalnih jedinica. Elementi P_{ij} definirani su na način da predstavljaju udjel teritorijalnih jedinica unutar dohodovne skupine i na početku razdoblja t , a koji su na kraju razdoblja $t+n$ klasificirani unutar dohodovne skupine j . Izračunavanjem vrijednosti matrice dobiva se jasna slika mobilnosti jedinica unutar pojedinih dohodovnih skupina bilo u višu ili nižu skupinu. Također, matrica omogućuje ukupnu ocjenu stabilnosti procesa, odnosno ukupne vjerojatnosti zadržavanja postojeće skupine. Prema Pellegrini (2002) indeks stabilnosti S za tranzicijsku matricu dimenzije n računa se kao: $S = Tr(P)/n$ pri čemu je $Tr(P)$ trag matrice P , odnosno suma elemenata na glavnoj dijagonali. Vrijednosti od S kreću se u intervalu od 0 do 1. Visoka razina vrijednosti od S upućuje na stabilan proces u kojem je vjerojatnost tranzicije teritorijalnih jedinica iz jedne skupine u drugu vrlo mala.

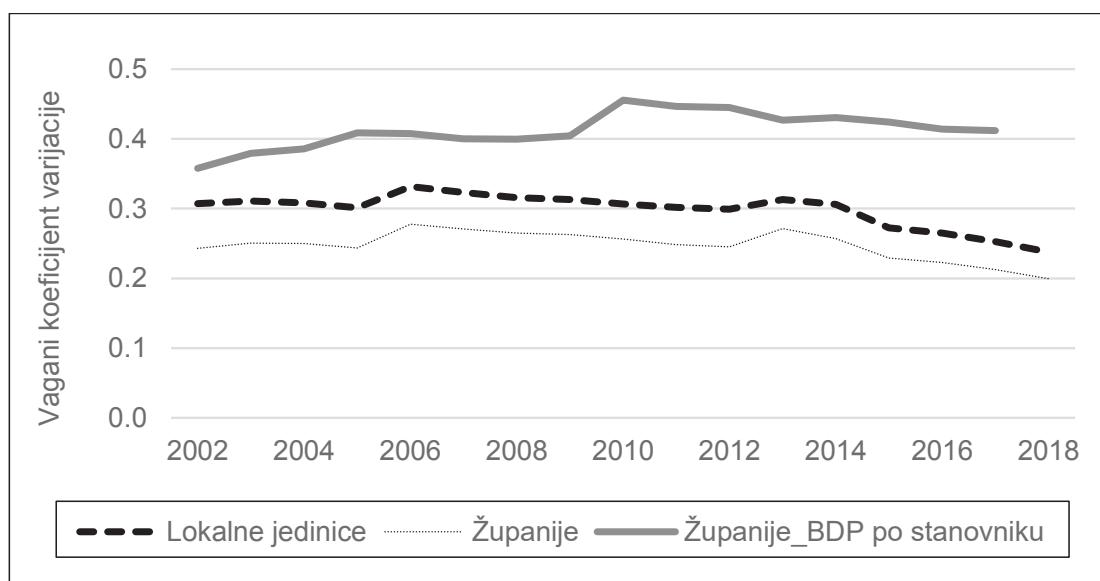
⁸ Ovaj podatak dostupan je samo iz popisa stanovništva, stoga se za analizu uzorka od 2002. do 2008. koristi podatak iz popisa stanovništva iz 2001., dok se za analizu u ostalim razdobljima koristi podatak iz popisa stanovništva iz 2011.

4. EMPIRIJSKI REZULTATI

U prvom koraku ocjenjuje se postojanje *sigma* konvergencije temeljem podataka o disperziji osobnih dohodaka po stanovniku na županijskoj i lokalnoj razini. Radi dodatne usporedbe, na županijskoj se razini analizira disperzija vrijednosti BDP-a po stanovniku. Podaci na slici 1. pokazuju da su se, u razdoblju 2002. – 2018., na županijskoj razini regionalne nejednakosti prema dohocima po stanovniku smanjile. Naročito snažno smanjenje bilježi se u razdoblju od 2014. do 2018. godine, a koje obilježava oporavak gospodarstva nakon duljeg razdoblja ekonomske krize. Podaci za lokalne jedinice u promatranom razdoblju također potvrđuju značajno smanjenje disperzije dohodaka po stanovniku, što potvrđuje prisutnost konvergencijskog trenda na lokalnoj razini. Ipak, uočljivi su određeni prekidi trenda. Primjerice, povećanje disperzije dohotka bilježi se u 2006. i, nešto blaže, u 2014., kada je vrijednost *sigma* konvergencije prešla, odnosno dostigla razinu početne vrijednosti iz 2002. godine. Za konačno smanjenje disperzije „zaslužan“ je trend u razdoblju od 2014. do 2018. kada se bilježi njezino ubrzano smanjenje. Također, valja uočiti kako nema jasne poveznice između disperzije dohodaka i ekonomskih ciklusa. Tako se, primjerice, za vrijeme gospodarskog rasta 2002. – 2008. bilježi prilično stabilna razina nejednakosti na lokalnoj razini, dok se na županijskoj razini bilježi povećanje nejednakosti. Međutim, u drugom razdoblju rasta, od 2015. do 2018. godine, obje teritorijalne razine bilježe značajno smanjenje nejednakosti.

Slika 1.

SIGMA KONVERGENCIJA OSOBNIH DOHODAKA NA ŽUPANIJSKOJ I LOKALNOJ RAZINI U HRVATSKOJ I BRUTO DOMAĆI PROIZVOD PO STANOVNIKU NA ŽUPANIJSKOJ RAZINI



Izvor: Izračun autora

S druge strane, podaci o kretanju BDP-a po stanovniku pokazuju da su se nejednakosti na županijskoj razini u istom razdoblju blago povećale. Pri tome se može uočiti značajan porast nejednakosti u razdoblju 2002. – 2010. te blagi pad nejednakosti u razdoblju 2011. – 2017. Razlike u pogledu dinamike regionalnih nejednakosti prema osobnim dohocima i BDP-u po stanovniku potvrđuje i negativna vrijednost koeficijenta korelacije između rasta BDP-a po stanovniku i rasta osobnih dohodaka po stanovniku na županijskoj razini ($r=-0,26$). Ovakav ishod je možda moguće povezati s nekoliko čimbenika. Dio razlika može biti povezan s promjenama u pogledu broja stanovnika. Npr., ako u pojedinim županijama imamo znatan odljev stanovnika koji imaju niske plaće za očekivati je da će u takvim sredinama doći do relativno većeg povećanja dohodaka po stanovniku u odnosu na BDP po stanovniku. Također, treba uzeti u obzir i efekt dnevnih migranata osoba s prebivalištem u susjednim županijama grada Zagreba, a koji rade u poslovnim subjektima sa sjedištem na području grada Zagreba. Oni svojim radom izravno doprinose rastu BDP-a grada Zagreba, dok se istovremeno porast njihovih osobnih dohodaka bilježi na području županije gdje imaju prebivalište.⁹ Također se može

⁹ Samo za ilustraciju, kumulativni rast BDP-a Zagrebačke županije u razdoblju 2002. – 2017. iznosio je 72,5 %, dok je porast osobnih dohodaka u istom razdoblju iznosio 121,1 %.

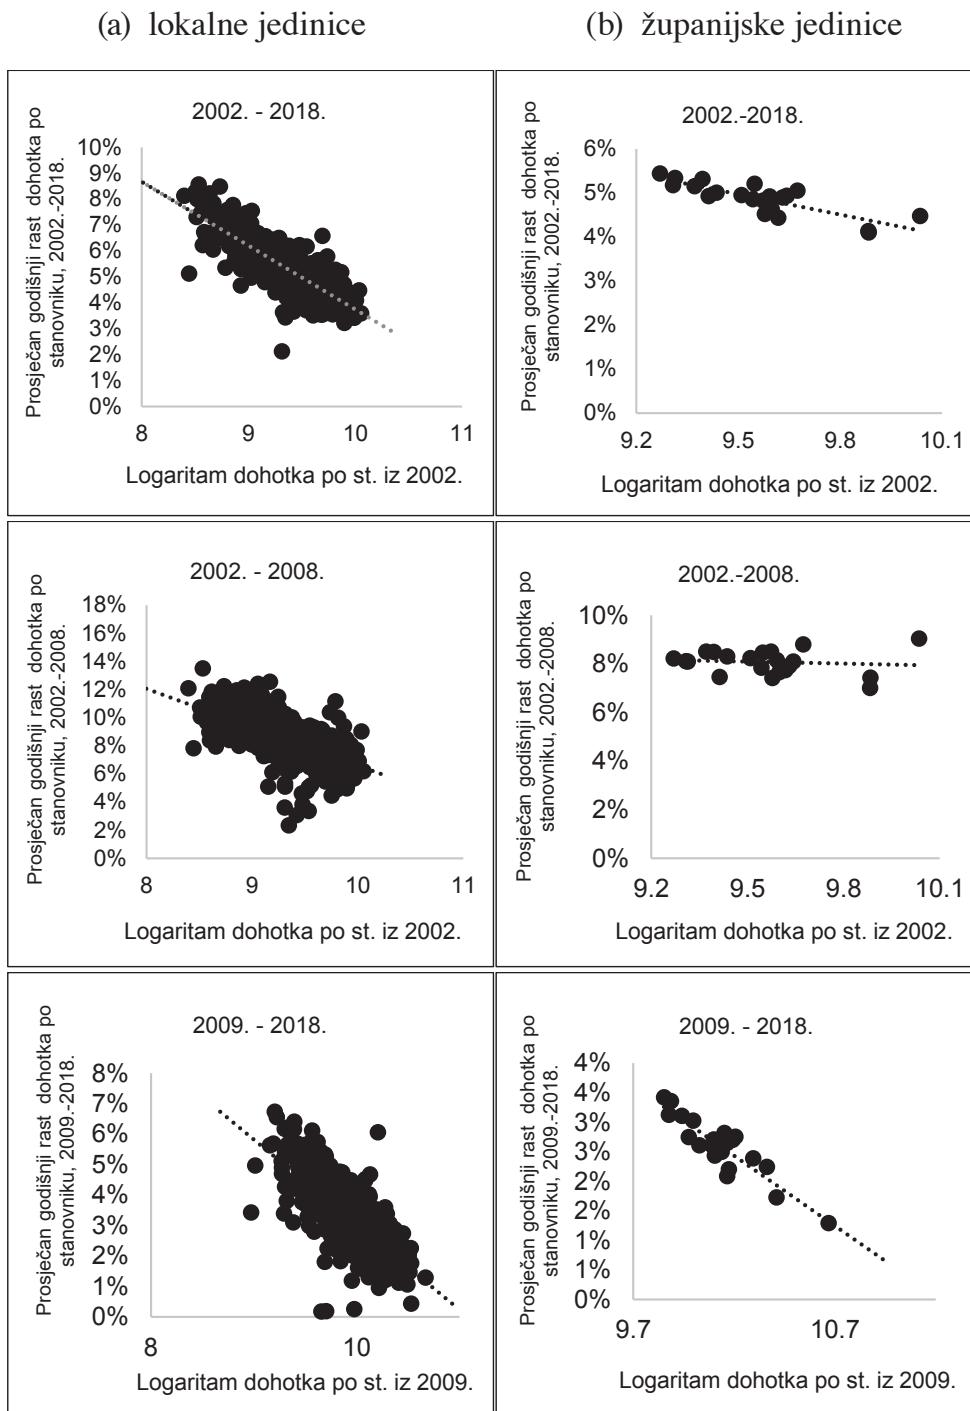
prepostaviti da je, kad se Hrvatska promatra u cjelini, dio razlika u dinamici rezultat općenito bržeg rasta nižih plaća u odnosu na prosječnu plaću, što vrlo vjerojatno ide u prilog županijama s nižim prosječnim osobnim dohocima.¹⁰ Ipak, bez detaljnijih podataka o distribuciji dohodaka unutar županijskih jedinica teško je procijeniti stvaran doprinos gore navedenih čimbenika. Drugo važno opažanje vezano za usporedbu osobnih dohodaka i BDP-a po stanovniku jest da su regionalne nejednakosti mjerene osobnim dohocima po stanovniku znatno niže. Konkretno, prema podacima za 2018. godinu, riječ je o dvostruko manjoj razini regionalnih nejednakosti kad su u pitanju osobni dohoci po stanovniku u odnosu na BDP po stanovniku. Navedeni rezultati pokazuju da se, gledano u duljem vremenskom razdoblju, te sagledavajući novije podatke, regionalne nejednakosti mjerene osobnim dohocima po stanovniku smanjuju, kako na županijskoj tako i na lokalnoj razini. Pri tome je nešto veći pad nejednakosti zabilježen na lokalnoj razini (smanjenje vrijednosti koeficijenta varijacije za 23,1 %) u odnosu na županijsku razini (-18 %).

U nastavku rada prikazana su testiranja prisutnosti absolutne i uvjetne *beta* konvergencije na županijskoj i lokalnoj razini kroz tri vremenska razdoblja. Kao što se može vidjeti iz tablice 1. rezultati testiranja absolutne konvergencije potvrđuju statistički značajnu prisutnost konvergencijskog procesa na lokalnoj i županijskoj razini, s izuzetkom razdoblja 2002. – 2008. na županijskoj razini. Brzina konvergencije na lokalnoj razini snažna je i prilično stabilna i kreće se na razini od oko 3,15 %, dok se vrijeme za dostizanje polovice od početnog zaostajanja procjenjuje na 22 godine. Na županijskoj razini brzina konvergencije je manja te iznosi 1,78 %, a generirana je snažnom konvergencijom u razdoblju 2009.-2018., dok u prethodnom razdoblju prisutnost konvergencijskog procesa nije zabilježena. Stoga je i razdoblje prepolavljanja početnih razlika znatno dulje nego ono na lokalnoj razini te iznosi 38,8 godina.

¹⁰ Za ovu tvrdnju nema dovoljno pouzdanih podataka za cijelo razdoblje. Ipak, podaci DZS-a za razdoblje 2016-2019. pokazuju da su neto plaće u prvom kvartilu (prema visini plaće) znatno brže rasle od plaće u četvrtom kvartilu, što može značiti da se slična dinamika bilježila i u ranijim godinama.

Slika 2.

STOPE RASTA I POČETNA RAZINA OSOBNIH DOHODAKA NA ŽUPANIJSKOJ I LOKALNOJ RAZINI



Izvor: Izračun autora

Tablica 1.

REZULTATI TESTIRANJA APSOLUTNE BETA KONVERGENCIJE

	period	konstanta	β_1	R ²	Brzina konvergencije	Pola života
Županije	2002.-2018.	0,19*** (8,37)	-0,0154*** (-6,29)	0,67	1,79%	38,67
	2002.-2008.	0,10* (1,94)	-0,0027 (-0,47)	0,01	/	/
	2009.-2018.	0,26*** (10,49)	-0,0237*** (-9,47)	0,82	2,71%	25,54
Lokalne jedinice	2002.-2018.	0,28*** (44,19)	-0,0246*** (-35,85)	0,70	3,18%	21,74
	2002.-2008.	0,33*** (24,75)	-0,0272*** (-18,63)	0,39	3,02%	22,93
	2009.-2018.	0,30*** (28,73)	-0,0279*** (-25,77)	0,55	3,27%	21,17

Napomena: *** označava značajnost na 1%, * označava značajnost na 10%. U zagradama je nazvana t-statistika

Izvor: Izračun autora

U idućem koraku provedeno je ispitivanje prisutnosti uvjetne *beta* konvergencije dohotka po stanovniku nakon što se uključe vrijednosti dodatnih nezavisnih varijabli. Svi regresijski modeli u nastavku testirani su na multikolinearnost¹¹ i heteroskedastičnost¹². Rezultati iz tablice 2. potvrđuju prisutnost konvergencijskog procesa na županijskoj razini i nakon uključivanja dodatnih varijabli i to uz visoku statističku pouzdanost. Međutim, to je isključivo posljedica konvergencije u razdoblju 2009. – 2018., dok uvjetna *beta* konvergencija nije potvrđena za razdoblje od 2002. do 2008. godine, što je u skladu s ranije dobivenim procjenama za apsolutnu konvergenciju. Zanimljivo je istaknuti da je brzina konvergencije u razdoblju 2009. – 2018. vrlo blizu stope od 2 % koja se vrlo često nalazi u literaturi. Kad je riječ o dodatnim varijablama, značajan utjecaj bilježi samo varijabla turizam koja za cijelo promatrano razdoblje ima negativan predznak, što bi značilo da su županije s većom turističkom aktivnosti povezane s nižom stopom rasta dohodaka. Među-

¹¹ Multikolinearnost se javlja kad je prisutna povezanost između nezavisnih varijabli. U testiranim modelima ne postoji problem multikolinearnosti.

¹² Heteroskedastičnost se javlja kad je narušena pretpostavka o nepromjenjivosti varijance u modelu. Ako se ona javi potrebno je koristiti neke od načina njezina rješenja. U testiranim regresijama prisutna je u četiri modela kod lokalnih jedinica, stoga će se u tim modelima koristiti heteroskedastično konzistentne greške relacije (engl. *white standard errors*).

tim, sam utjecaj varijable na rast dohotaka vrlo je slab, posebno u razdoblju 2009. – 2018. Što se tiče druge dvije varijable, obrazovanja i stanovništva, niti jedna se nije pokazala statistički značajnom varijablu. Ipak, zanimljivo je primijetiti kako se kod varijable obrazovanje predznak mijenja pa nakon pozitivnog predznaka u razdoblju 2002. – 2008., postaje negativan u razdoblju 2009. – 2018. Također, treba naglasiti kako nema bitnih razlika između vrijednosti dobivenih OLS i WLS metodom, što znači da veličina jedinica nije imala poseban utjecaj na proces konvergencije na županijskoj razini. Vrijednost pokazatelja pola života pokazuje da bi se zadržavanjem stopa konvergencije iz razdoblja 2009. – 2018. tek za 30-ak godina moglo očekivati prepolavljanje postojećih razlika na županijskoj razini.

Tablica 2.

UVJETNA BETA KONVERGENCIJA ZA ŽUPANIJE
(ZAVISNA VARIJABLA: PROSJEČAN GODIŠNJI RAST DOHOTKA

$$\text{PO STANOVNIKU, } T^{-1} \ln \left(\frac{y_{iT}}{y_{i0}} \right)$$

	2002.-2018.		2002.-2008.		2009.-2018.	
	Model 1	Model 2	Model 3	Model 4	Model 5	Model 6
	OLS	WLS	OLS	WLS	OLS	WLS
Ln_dohotka početne godine (2002. ili 2009.)	-0,0111*** (-3,53)	-0,0100*** (-3,63)	0,0045 (0,55)	0,0046 (0,61)	-0,0211*** (-4,14)	-0,0202*** (-3,97)
obraz	0,0520 (0,60)	0,0552 (0,68)	0,0339 (1,60)	0,0397 (0,76)	-0,0125 (-0,76)	-0,0137 (-0,91)
stan	0,0077 (1,27)	0,0080 (1,32)	0,0158 (0,51)	0,0218 (0,76)	0,0087 (0,67)	0,0083 (0,63)
turizam	-0,0009*** (-3,22)	-0,0010*** (-4,10)	-0,0022*** (-3,81)	-0,0025*** (-5,16)	-0,0001 (-0,34)	-0,0001 (-0,58)
_konstanta	0,16*** (5,85)	0,15*** (6,29)	0,06 (0,82)	0,06 (0,92)	0,24*** (-4,14)	0,23*** (4,69)
F statistika (p-vrijednost)	17,01 (0,0000)	20,05 (0,0000)	4,66 (0,0110)	13,66 (0,0000)	20,51 (0,0000)	28,03 (0,0000)
Breusch-Pagan/Cook-Weisberg (p-vrijednost)	0,10 (0,7564)	0,55 (0,4590)	1,39 (0,2391)	0,20 (0,6558)	0,01 (0,9567)	0,20 (0,6559)
Broj prostornih jedinica	21	21	21	21	21	21
R ²	0,81	0,83	0,53	0,77	0,83	0,87
Brzina konvergencije	1,23%	1,10%	/	/	2,37%	2,26%
Pola života	56,13	62,67	/	/	29,20	30,66

Izvor: Izračun autora

Rezultati testiranja uvjetne konvergencije na lokalnoj razini predstavljeni su u tablici 3. Vrijednosti R^2 za sve modelle i razdoblja i dalje su prilično visoki, iako su nešto niži nego za županijsku razinu. Procjena OLS metodom ukazuje na snažniji proces konvergencije nego na županijskoj razini te njezinu prisutnost kroz sva razdoblja, s tim da je proces očekivano snažniji u razdoblju 2009. – 2018. Statistički značajna pokazuje se varijabla stanovništvo, pri čemu je njezin predznak negativan. To bi značilo da lokalne jedinice koje bilježe smanjenje broja stanovnika u prosjeku bilježe veće stope rasta dohodaka. Najsnažniji utjecaj i statistički najznačajniji zabilježen je u razdoblju 2002. – 2008. Ovakav je odnos, vrlo vjerojatno, povezan s procesom iseljavanja radno aktivnog stanovništva bez zaposlenja ili s vrlo niskim dohocima te odumiranja starijeg stanovništva s vrlo niskim dohocima, što je imalo za posljedicu bolju dinamiku rasta dohodaka po stanovniku nego u sredinama u kojima su negativni demografski procesi bili manje izraženi. U razdoblju 2009. – 2018. ova povezanost, premda i dalje negativna, više nije statistički značajna. Turizam je iduća statistički značajna varijabla koja ima negativan predznak za cijelo promatrano razdoblje, s tim da u razdoblju 2009. – 2018. dolazi do promjene te predznak postaje pozitivan, ali je veza znatno slabija nego u pretvodnom razdoblju. Može se zaključiti da se povezanost turizma i rasta dohodaka s vremenom mijenja te da nakon 2009. dominira pozitivna povezanost, što je u skladu s izraženim trendom jačanja utjecaja turizma na nacionalno gospodarstvo. U slučaju visokog obrazovanja utvrđena je vrlo slaba veza, bez statističke značajnosti. Primjena WLS metode dovela je do blago veće brzine konvergencije te do slabije važnosti varijable turizam, ali ukupno gledano razlike u odnosu na OLS metodu su izuzetno male.

Tablica 3.

UVJETNA BETA KONVERGENCIJA ZA LOKALNE JEDINICE
(ZAVISNA VARIJABLA: PROSJEČAN GODIŠNJI RAST DOHOTKA

$$\text{PO STANOVNiku}, T^{-1} \ln \left(\frac{y_{iT}}{y_{i0}} \right) - \text{UMETNITE OVDJE}$$

	2002.-2018.		2002.-2008.		2009.-2018.	
	Model 7	Model 8	Model 9	Model 10	Model 11	Model 12
	OLS	WLS	OLS	WLS	OLS	WLS
Ln_dohotka početne godine (2002. ili 2009.)	-0,0230*** (-19,62)	-0,0231*** (-19,63)	-0,0203*** (-11,09)	-0,0204*** (-11,20)	-0,0267*** (-15,60)	-0,0270*** (-17,84)
obraz	-0,0000 (-0,01)	0,0006 (0,11)	-0,0103 (-1,17)	-0,0126 (-1,41)	-0,0069 (-0,94)	-0,0004 (-0,09)
stan	-0,0034* (-1,83)	-0,0034* (-1,84)	-0,0409*** (-7,47)	-0,0406*** (-7,43)	-0,0044 (-0,95)	-0,0039 (-1,03)
turizam	-0,0015* (-1,95)	-0,0015** (-2,02)	-0,0031* (-1,92)	-0,0029* (-1,77)	0,0016* (1,73)	0,0006 (0,69)
_konstanta	0,26*** (25,44)	0,27*** (25,44)	0,27*** (16,69)	0,27 (16,83)	0,29*** (17,97)	0,30*** (20,38)
F statistika (p-vrijednost)	310,04 (0,0000)	305,05 (0,0000)	128,62 (0,0000)	131,09 (0,0000)	162,32 (0,0000)	225,45 (0,0000)
Breusch-Pagan/Cook-Weisberg (p-vrijednost)	-	-	2,09 (0,1485)	2,22 (0,1360)	-	-
Broj prostornih jedinica	540	540	540	540	540	540
R ²	0,71	0,71	0,49	0,49	0,55	0,62
Brzina konvergencije	2,93%	2,94%	2,19%	2,21%	3,11%	3,15%
Pola života	23,66	23,61	31,61	31,36	22,29	22,00

Izvor: Izračun autora

U zadnjem dijelu empirijskog testiranja ispitana je mobilnost lokalnih i županijskih jedinica u pogledu promjene relativnog položaja prema razini osobnih dohodaka po stanovniku korištenjem tzv. matrice prijelaznih vjerojatnosti, koja pokazuje u kojoj mjeri su prisutne promjene položaja teritorijalnih jedinica u ukupnoj distribuciji kroz vrijeme, odnosno računa vjerojatnosti zadržavanja postojećeg relativnog položaja pojedinih kategorija jedinica. U ovom se slučaju položaj računa kao dohodovna skupina. Sve jedinice podijeljene su u skupine na način da svaka skupina predstavlja jedan kvintil distribucije jedinica prema osobnim dohodima po stanovniku. Tablica 4 daje vrijednosti matrice. Vrijednosti u matrici predstavljaju udjele jedinica koje su u razdoblju 2002. – 2018. promijenile skupinu odnosno

koje su ostale u istoj skupini. Temeljem vrijednosti na dijagonali matrice može se izračunati tzv. indeks stabilnosti S koji predstavlja prosjek vrijednosti na dijagonali i koji daje sumarnu ocjenu ukupne stabilnosti jedinica. Visoka vrijednost S podrazumijeva visoku vremensku stabilnost promatranih jedinica, odnosno vjerojatnost da jedinice promijene položaj u tom je slučaju prilično mala. Vrijednost S indeksa za matricu iznosi 0,638 što se može interpretirati kao umjerena stabilnost lokalnih jedinica u pogledu promjene njihovog relativnog položaja. Pritom, međutim, postoje značajne razlike u pojedinim dijelovima distribucije. Kako se može vidjeti, jedinice u prvom i petom kvintilu bilježe visoku razinu stabilnosti, što znači da je vjerojatnost promjene njihovog relativnog položaja prilično mala. Svega 18 % lokalnih jedinica, koje su 2002. bile u prvom kvintilu, promijenile su skupinu u 2018. godini, od čega je svega 2 % završilo u trećem kvintilu. To pokazuje kako se položaj najslabije razvijenih jedinica vrlo teško mijenja. Vrlo sličan zaključak vrijedi za jedinice u petom kvintilu, gdje se pokazalo da je 79 % jedinica uspjelo zadržati istu skupinu. S druge strane, jedinice u drugom, trećem i četvrtom kvintilu znatno su mobilnije, te se bilježe znatne promjene položaja. To se posebno odnosi na jedinice u trećem kvintilu gdje je manje od polovice jedinica zadržalo istu skupinu. Najveći doprinos konvergenciji ostvarile su jedinice u drugom kvintilu, čak njih 32 % prešlo je u višu skupinu prema razini dohotka po stanovniku. Također, vidljivo je da se promjene položaja u srednjem dijelu distribucije odvijaju u oba smjera, te da su kod jednog manjeg dijela jedinica zabilježeni pomaci prema gore ili prema dolje za čak dvije skupine.

Tablica 4.

MATRICA PRIJELAZNIH VJEROJATNOSTI NA LOKALNOJ RAZINI

		Skupina (kvintil)	Udio u uk. stanovništvu (2002.)	2018.				
				Q1	Q2	Q3	Q4	Q5
2002.	Q1	0,07	82%	16%	2%			
	Q2	0,09	14%	55%	26%	6%		
	Q3	0,12	4%	27%	48%	21%	1%	
	Q4	0,18		3%	22%	55%	20%	
	Q5	0,53			3%	18%	79%	
Indeks stabilnosti S				0,638				

Izvor: Izračun autora

Na županijskoj razini rezultati očekivano ukazuju na slabiju mobilnost od one na lokalnoj razini. Međutim, smjer mobilnosti sličan je u smislu da je na krajnjima distribucije mobilnost najslabija, dok je najveća u srednjem dijelu, s tim da kod županija uopće nema mobilnosti u prvom i petom kvintilu. Ukratko, najslabije i najrazvijenije županije svoj relativni položaj ne mijenjaju, već se proces konvergencija odvija kroz promjene u drugom, trećem i četvrtom kvintilu. Također, slično kao i kod lokalne razine, promjene položaja u srednjem dijelu distribucije uglavnom se odvijaju u oba smjera

Tablica 5.

MATRICA PRIJELAZNIH VJEROJATNOSTI NA ŽUPANIJSKOJ RAZINI

		Skupina (kvintil)	Udio u uk. stanovništvu (2002.)	2018.				
				Q1	Q2	Q3	Q4	Q5
2002.	Q1	0,13	100%					
	Q2	0,11		75%	25%			
	Q3	0,21		25%	25%	50%		
	Q4	0,15			50%	50%		
	Q5	0,39						100%
Indeks stabilnosti S		0,70						

Izvor: Izračun autora

5. ZAKLJUČAK

U radu se ispituje prisutnost procesa konvergencije unutar Hrvatske u razdoblju 2002. – 2018. To je razdoblje analize znatno dulje od razdoblja u dosadašnjim radovima koji su se bavili sličnom tematikom. Korištenje podataka o osobnim dohodima omogućilo je da se testiranje konvergencije osim na razini županije procjeni i na lokalnoj razini. Pri tome se u radu koristi niz različitih metoda što omogućuje prilično cjeloviti uvid u dinamiku i čimbenike povezane s regionalnim nejednakostima. Rezultati empirijske analize doveli su do nekoliko važnih saznanja. Prije svega, pokazalo se da su regionalne nejednakosti u Hrvatskoj prema osobnom dohotku po stanovniku znatno manje nego u slučaju BDP-a po stanovniku

(čak dvostruko manje). Nadalje, rezultati ukazuju na to da je u razdoblju 2002. – 2018. prisutna konvergencija osobnih dohodaka po stanovnika posebno izražena na lokalnoj razini, dok se u slučaju BDP-a po stanovniku bilježi povećanje nejednakosti na županijskoj razini (iako uz primjetan pad nejednakosti u razdoblju 2011. – 2017.). Drugim riječima, regionalne razlike prema razini standarda življenja stanovnika mјerenog osobnim dohocima su se znatno smanjile, što nije slučaj u pogledu razlika u proizvodnosti regionalnih gospodarstava koje su blago porasle.

Testiranje absolutne i uvjetne *beta* konvergencije potvrdilo je prisutnost procesa konvergencije kroz niz različitih specifikacija modela. Pri tome se uočavaju određene promjene u trendu pa se u razdoblju 2002. – 2008. bilježi slabija (lokalne jedinice) ili nikakva (županije) konvergencija, dok razdoblje 2009. – 2018. obilježava snažan proces konvergencije kako na lokalnoj tako i na županijskoj razini. Kod modela uvjetne konvergencije kao statistički značajne varijable u različitim specifikacijama modela pojavljuju se turistička razvijenost (županijska i lokalna razina) te kretanje stanovnika (lokalna razina). Za razliku od županijske razine gdje je veza kontinuirano negativna, na lokalnoj se razini povezanost turizma s rastom dohodaka mijenja te on od negativno povezanog s vremenom postaje pozitivno povezan, što je, očigledno, povezano sa snažnim razvojem turizma tijekom posljednjih desetak godina. Negativan utjecaj promjene broja stanovnika može se povezati s, naizgled, paradoksalnom situacijom u kojoj smanjenje broja stanovnika zbog iseljavanja i niskog prirodnog priraštaja vodi većem raspoloživom dohotku preostalog stanovništva. Konačno, analiza temeljem matrice prijelaznih vjerojatnosti pokazala je kako se proces konvergencije uglavnom odvija kroz promjene u srednjem dijelu distribucije, dok teritorijalne jedinice (kako lokalne tako i županijske) na krajevima puno teže ostvaruju prijelaze prema sredini. Očekivano, mobilnost jedinica je nešto veća na lokalnoj nego na županijskoj razini.

Zaključno, analiza je pokazala da su, kad je riječ o osobnim dohocima po stanovniku, u Hrvatskoj prisutne opadajuće nejednakosti, kako na županijskoj tako i na lokalnoj razini, što je novo saznanje u odnosu na često izražene javne percepcije o rastućim regionalnim razlikama. Time se ujedno potvrđuje potreba za sagledavanjem regionalnih nejednakosti kroz alternativne indikatore pored BDP-a po stanovniku. Također, rezultati pokazuju kako je gospodarski oporavak nakon 2014. godine bio „dobar“ za regionalne nejednakosti, budući da se u tom razdoblju bilježi njihov snažan pad. Međutim, s druge strane, kvaliteta procesa smanjenja nejednakosti je problematična jer dio siromašnijih lokalnih i županijskih jedinica i dalje ima vrlo male šanse promijeniti svoj relativan položaj. Stoga bi nositelji regionalne politike trebali dodatnu pažnju i resurse usmjeriti prema takvim područjima.

Za buduća bi istraživanja bilo korisno ispitati učinak prostornih čimbenika na dinamiku rasta odnosno regionalnih nejednakosti. To bi poglavito bilo važno za lokalnu razinu gdje je u pogledu rasta vrlo vjerojatno prisutna znatna prostorna međuovisnost.

LITERATURA

1. Arbia, G., Basile, R., Salvatore, M. (2003). Measuring spatial effects in parametric and nonparametric modelling of regional growth and convergence. Paper prepared for the UNU/WIDER Project Meeting on spatial inequality in development, Helsinki, 29 May 2003. Dostupno na: https://rimisp.org/wp-content/files_mf/1363094049arbia_et_al_2003_spatial_effects_regiona...
2. Azariadis, C. (1996). The Economics of Poverty Traps Part One: Complete Markets. *Journal of Economic Growth*, 1(4), 449-486. Dostupno na: <https://www.jstor.org/stable/40215925>
3. Barro, R.J. Sala-i-Martin, X. (1992). Convergence. *Journal of Political Economy*, 100(2), 223-251. doi:10.1086/261816
4. Barro, R.J. Sala-i-Martin, X. (2004) Economic growth, Cambridge, MIT Press
5. Castro J. V. (2003). Regional Convergence, Polarisation and Mobility in the European Union, 1980-1996, *Journal of European Integration*, 25(1), 73-86. <https://doi.org/10.1080/0703633031000077172>
6. Chatterji M., Dewhurst, J. (1996). Convergence Clubs and Relative Economic Performance in Great Britain: 1977-1991. *Regional Studies*, 30(1), 31-39. <https://doi.org/10.1080/00343409612331349458>
7. Chatterji, M. (1992). Convergence Clubs and Endogenous Growth. *Oxford Review of Economic Policy*, 8(4), 57-69. Dostupno na: <https://www.jstor.org/stable/23606277>
8. Chocholatá, M. i Furková, A. (2016). Income disparities and convergence across regions of Central Europe. *Croatian Operational Research Review*, 7(2), 303-318. <https://doi.org/10.17535/crorr.2016.0021>
9. Cole, M. A., Neumayer, E. (2003). The pitfalls of convergence analysis: is the income gap really widening?. London, LSE Research online. Dostupno na: <http://eprints.lse.ac.uk/603/>
10. Durlauf, S. (1993). Nonergodic Economic Growth. *Review of Economic Studies*, 60(2), 349-366. <https://doi.org/10.2307/2298061>
11. De la Fuente A. (2002). On the sources of convergence: A close look at the Spanish regions. *European Economic Review*, 46(3), 569–599. [https://doi.org/10.1016/S0014-2921\(01\)00161-1](https://doi.org/10.1016/S0014-2921(01)00161-1)
12. Drezgić, S. (2011). Public investments and regional income convergence: empirical analysis of Croatian regions. *Socialiniai tyrimai / Social Research*, 3(24), 43-55. Dostupno na: <http://www.journals4free.com/link.jsp?l=36484836>

13. Đokić, I., Fröhlich, Z., Rašić Bakarić, I. (2016). The impact of the economic crisis on regional disparities in Croatia. *Cambridge Journal of Regions, Economy and Society*, 9(1), 179-195. <https://doi.org/10.1093/cjres/rsv030>
14. Galor, O. (1996). Convergence? Inferences from theoretical models. *Economic Journal* 106(473), 1056-1069. <https://doi.org/10.2307/2235378>
15. HoferH., Wörgötter,A.(1997).Regional Per Capita Income Convergence in Austria. *Regional Studies*, 31(1), 1-12. <https://doi.org/10.1080/00343409750134746>
16. Le Gallo J. 2004. Space-time analysis of GDP disparities among European regions: A Markov chains approach. *International Regional Science Review*, 27(2), 138-165. <https://doi.org/10.1177%2F0160017603262402>
17. Lopes, J.C., Araújo, T. (2016). Geographic and Demographic Determinants of Regional Growth and Convergence: a Network Approach. *Revista Portuguesa de Estudos Regionais*, no. 43, 32-47. Dostupno na: <https://dialnet.unirioja.es/servlet/articulo?codigo=5682125>
18. López-Bazo E., Vayá E., Mora A.J., Suriñach J. (1999). Regional economic dynamics and convergence in the European Union. *Annals of Regional Science*, 33(3), 343–370. <https://doi.org/10.1007/s001680050109>
19. Mankiw, G., Romer, D., Weil, D. (1992). A contribution to the empirics of economic growth. *Quarterly Journal of Economics*, 107(2), 407-437. <https://doi.org/10.2307/2118477>
20. Magrini, S. (1999). The evolution of income disparities among the regions of the European Union. *Regional Science and Urban Economics*, 29(2), 257-281. [https://doi.org/10.1016/S0166-0462\(98\)00039-8](https://doi.org/10.1016/S0166-0462(98)00039-8)
21. Mikulić, D., Galić Nagyszombaty, A. (2015). Does international trade cause regional growth differentials in Croatia?. *Zbornik radova Ekonomskog fakulteta u Rijeci*, 33(1), 81-102. Dostupno na: <https://hrcak.srce.hr/139930>
22. Mikulić, D., Lovrinčević, Ž., Galić Nagyszombaty, A. (2013). Regional convergence in the European union, new member states and Croatia. *South East European Economics and Business*, 8(1), 7-19. <https://doi.org/10.2478/jeb-2013-0001>
23. Munteanu, A. (2015). Regional convergence in Romania: from theory to empirics. *Procedia Economics and Finance*, 32(2015), 160-165. [https://doi.org/10.1016/S2212-5671\(15\)01378-7](https://doi.org/10.1016/S2212-5671(15)01378-7)
24. Niebuhr, A. (2001). Convergence and the effects of Spatial Interaction. *HWWA Discussion Paper No. 110*, Hamburg Institute of International Economics (HWWA), Hamburg. Dostupno na: <https://www.econstor.eu/bitstream/10419/19441/1/110.pdf>

25. Pellegrini, G. (2002). Proximity, Polarization, and Local Labor Market Performances. *Networks and Spatial Economics*, 2(2), 151-173. <https://doi.org/10.1023/A:1015313212056>
26. Persson, J. (1997). Convergence across the Swedish counties, 1911-1993. *European Economic Review*, 41(9), 1835-1852. [https://doi.org/10.1016/S0014-2921\(96\)00053-0](https://doi.org/10.1016/S0014-2921(96)00053-0)
27. Petrakos, G., Artelaris, P. (2009). European regional convergence revisited: a weighted least squares approach. *Growth and Change*, 40(2), 314-331. <https://doi.org/10.1111/j.1468-2257.2009.00477.x>
28. Petrakos, G., Kallioras, D., Anagnostou, A. (2011). Regional convergence and growth in Europe: understanding patterns and determinants. *European Urban and Regional Studies* 18(4), 375-391. <https://doi.org/10.1177%2F0969776411407809>
29. Petrakos, G., Psacharidis Y., Kallioras, D. (2005) Regional inequalities in the EU Accession Countries: Evolution and Challenges. In: Bradley J, Petrakos G. and Traistaru I. (Ur.) *Integration, Growth and Cohesion in an Enlarged European Union*, Springer, New York, 45-64.
30. Piętak, Łukasz (2015). Convergence across Polish regions, 2005-2011. *Comparative Economic Research*, 18(2), 99-118. <http://dx.doi.org/10.1515/cer-2015-0014>
31. Portnov, B.A., Felsenstein D. (2005). Measures of Regional Inequality for Small Countries, in Felsenstein D., Portnov B. (Ur.) *Regional disparities in small countries*, Springer, Berlin, 47-62.
32. Puljiz J., Maleković S. (2007). Regional Income and Unemployment Disparities in Croatia, Conference proceedings, 7th International Conference Enterprise in Transition. University of Split, May 24-26, 2007, Bol. Dostupno na: https://bib.irb.hr/datoteka/332497.Full_Paper_Disparities.pdf
33. Quah, D. (1993). Empirical cross-section dynamics in economic growth. *European Economic Review* 37(2-3), 426-434. [https://doi.org/10.1016/0014-2921\(93\)90031-5](https://doi.org/10.1016/0014-2921(93)90031-5)
34. Quah, D. (1996) Empirics for economic growth and convergence. *European Economic Review*, 40(6), 1353-1375. [https://doi.org/10.1016/0014-2921\(95\)00051-8](https://doi.org/10.1016/0014-2921(95)00051-8)
35. Siriopoulos C., Asteriou, D. (1998). Testing for Convergence Across the Greek Regions, *Regional Studies*, 32(6), 537-546. <https://doi.org/10.1080/00343409850119102>.
36. Solow, R.M. (1956). A contribution to the theory of economic growth, *Quarterly Journal of Economics*, 70(1), 65-94. <https://doi.org/10.2307/1884513>.

37. Sorens, J. (2014). Does Fiscal Federalism Promote Regional Inequality? An Empirical Analysis of the OECD, 1980–2005. *Regional Studies* 48(2), 239-253. <https://doi.org/10.1080/00343404.2012.661851>
38. Soukiazis, E., Antunes, M. (2004). The evolution of real disparities in Portugal among NUTS III regions. An empirical analysis based on convergence approach. 44th Congress of the European Regional Science Association: “Regions and Fiscal Federalism”, 25th – 29th August 2004, Porto, Portugal, European Regional Science Association (ERSA), Louvain-la-Neuve. Dostupno na: <https://www.econstor.eu/handle/10419/116952>

CONVERGENCE PROCESS ANALYSIS AT THE LOCAL AND REGIONAL LEVELS IN CROATIA

Summary

Based on personal income data the paper analyses the convergence process at the local and county levels in the Republic of Croatia between 2002 and 2018 using the concept of *sigma* and *beta* convergence. In addition, mobility of local and county units was tested using the transition probability matrix based on the Markov chain. The results of the conducted research indicate the reduction of income inequalities at the local and county levels and the presence of absolute and conditional *beta* convergence. Further analysis shows that convergence is markedly stronger after 2014. The results of the transition probability matrix suggest that the convergence process takes place primarily through changes in the middle part of the distribution. In other words, the poorest local and county units still have very little chance of changing their relative position.

Key words: regional inequalities, convergence, personal incomes, local development, regional development, Croatia