# Značaj specijalizacije regija za regionalnu konvergenciju u Europskoj uniji

**Ujević, Ivana**

**Professional thesis / Završni specijalistički**

**2017**

*Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj:* **University of Split, Faculty of economics Split / Sveučilište u Splitu, Ekonomski fakultet**

*Permanent link / Trajna poveznica:* https://urn.nsk.hr/urn:nbn:hr:124:558561

*Rights / Prava:* In copyright / Zaštićeno autorskim pravom.

*Download date / Datum preuzimanja:* **2024-04-20**

*Repository / Repozitorij:*

REFST - Repository of Economics faculty in Split

zir.nsk.hr

UNIVERSITY OF SPLIT

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

**SVEUČILIŠTE U SPLITU**
**EKONOMSKI FAKULTET**

**POSLIJEDIPLOMSKI SPECIJALISTIČKI STUDIJ**
**EKONOMIJA**

**ZAVRŠNI RAD**

# ZNAČAJ SPECIJALIZACIJE REGIJA ZA REGIONALNU KONVERGENCIJU U EUROPSKOJ UNIJI

**Mentor:**

**Doc. dr. sc. Vinko Muštra**

**Poslijediplomant:**

**Ivana Ujević, mag. oec.**

**Split, veljača 2017.**

**SADRŽAJ:**

**SAŽETAK** ..... **4**

**SUMMARY** ..... **5**

**1. UVOD** ..... **6**

1.1 Problem istraživanja ..... 7

1.2 Svrha i ciljevi istraživanja ..... 8

1.3 Ocjena dosadašnjih istraživanja ..... 9

1.4 Metode istraživanja ..... 12

1.5 Kompozicija rada ..... 13

**2. TEORIJSKI KONCEPTI RELEVANTNI ZA FENOMEN KONVERGENCIJE** ..... **15**

2.1 Neoklasični koncept rasta ..... 16

2.2 Koncept endogenog rasta ..... 19

2.3 Koncept izvozne baze ..... 21

2.4 Koncept polova rasta ..... 23

2.5 Koncept kumulativne uzročnosti ..... 25

2.6 Koncept Nove ekonomske geografije ..... 29

**3. EMPIRIJSKA ISTRAŽIVANJA KONVERGENCIJE** ..... **33**

3.1 Regresijski pristup ..... 33

3.1.1 Prostorna regresija ..... 33

3.1.2 Panel regresija ..... 36

3.1.3 Analiza vremenskih serija ..... 38

3.2 Pristup distribucijske dinamike ..... 42

**4. ZNAČAJ SPECIJALIZACIJE ZA REGIONALNI RAZVOJ ..... 51**

4.1 Teorijske odrednice specijalizacije regija ..... 51

4.2 Definiranje pojma i kvantifikacija specijalizacije regija ..... 64

4.3 Specijalizacija regija u EU ..... 69

**5. REZULTATI EMPIRIJSKOG ISTRAŽIVANJA ..... 72**

5.1 Metodološki aspekti empirijskog istraživanja ..... 77

5.2 Analiza podataka i rezultati empirijskog istraživanja ..... 78

5.3 Ocjena istraživačkih hipoteza ..... 87

**6. ZAKLJUČAK ..... 93**

6.1 Sažetak rezultata istraživanja ..... 93

6.2 Doprinosi i implikacije istraživanja ..... 101

6.3 Ograničenja provedenog istraživanja i mogućnosti za daljnja istraživanja ..... 102

**POPIS LITERATURE ..... 104**

**PRILOZI: ..... 114**

**POPIS TABLICA ..... 156**

**POPIS GRAFIČKIH PRIKAZA ..... 157**

## SAŽETAK

Konvergencija je u svim svojim pojavnim oblicima vrlo privlačna ideja s ekonomskog i socijalnog stajališta, stoga ne čudi što zanimanje istraživača za ovu temu ne jenjava već dugi niz godina. Determinante konvergencije pojavljuju se i na strani ponude i na strani potražnje ekonomije, a pojavni oblici su brojni, od ljudskog i fizičkog kapitala te njihovih različitih interaktivnih nusproizvoda. Fokus ovog rada je na istraživanju procesa konvergencije regija u Europskoj uniji s obzirom na sektorsku specijalizaciju regija.

Nakon pregleda relevantnih teorijskih i empirijskih dostignuća, formuliran je metodološki okvir kojem je zadatak ispitati utemeljenost postavljene glavne hipoteze prema kojoj je realna konvergencija regija Europske unije uvjetovana njihovom specijalizacijom.

Glavna radna hipoteza razrađena je na četiri pomoćne hipoteze koje su postavljene za empirijsko testiranje na podacima za 247 NUTS II regija u 14-godišnjem razdoblju od 2000. do 2013. godine. Prvom pomoćnom hipotezom potvrđeno je kako specijalizacija regija Europske unije utječe na razinu produktivnosti istih. Daljnjom analizom potvrđena je i druga pomoćna hipoteza prema kojoj su razlike u produktivnosti među regijama rezultat razlika u produktivnosti među sektorima njihovih specijalizacija. Konačno, trećom i četvrtom pomoćnom hipoteza ispitan je parcijalan utjecaj određenih sektora specijalizacije na gospodarski rast. Konkretno, trećom pomoćnom hipotezom potvrđeno je da regije specijalizirane za financijske i poslovne usluge te regije specijalizirane u sektorima visoke dodane vrijednosti ostvaruju više stope rasta u odnosu na ostale regije. S druge strane, sektor poljoprivrede je pokazao je nižu produktivnost i sukladno tome negativan utjecaj na rast, što je rezultat potvrde četvrte pomoćne hipoteze.

Sintezom iznesenog zaključuje se da je potvrdom i unakrsnim ispitivanjem pomoćnih hipoteza potvrđena glavna hipoteza, što implicira generalni zaključak kako je sektorska specijalizacija relevantna za realnu konvergenciju regija u Europskoj uniji.



**Ključne riječ**i: reginalna konvergencija, sektorska specijalizacija, produktivnost, panel regresija

## SUMMARY

The convergence hypothesis is very attractive idea from an economic and social point of view, hence it is not surprising that interest in research on this topic has not subside for a decades. Determinants of convergence appear both on the supply and the demand side of the economy. Those determinants are numerous and comes in a forms of human and physical capital and also in their different interactive byproducts. The focus of this research is to examine the convergence process of European Union regions regarding their sectoral specialization.

After reviewing the relevant theoretical and empirical achievements, the methodological framework has been done to empirically verify the main hypothesis according to which the real convergence process of European Union regions is determined by their specialization structure.

The main working hypothesis is elaborated on four supplementary hypotheses that are set to empirical testing on the data for 247 European Union NUTS II regions in the 14-year period from 2000 to 2013. The first supplementary hypothesis confirmed that specialization of European Union affects the regions level of productivity. Further analysis confirmed the second supplementary hypothesis, according to which the differences in productivity between regions arise from differences in productivity between sectors of their specialization. Finally, the third and fourth supplementary hypotheses have been tested to examine the partial influence of certain sectors of specialization on economic growth. In particular, the third supplementary hypothesis confirmed that the regions specialized in financial and business services, and in other high value added sectors achieves higher growth rates compared to other regions. On the other hand, the agricultural sector has demonstrated a lower productivity and consequently a negative impact on growth, resulting with confirmation of the fourth supplementary hypothesis.

Overall, the cross-examination of supplementary hypotheses confirmed the main hypothesis, which implies a general conclusion that the real convergence of European Union regions is affected by theirs sectoral specialization.

**Keywords:** regional convergence, sectoral specalization, productivity, panel regression

# 1. UVOD

Dok se regionalna ekonomija nije etablirala kao znanstvena disciplina, regija i njen razvoj promatrali su se iz različitih kuteva društvenih znanosti. Danas je prepoznata kao iznimno dinamično područje koje objedinjuje sociološke, političke, demografske, prostorne, ekološke i nadasve ekonomske promjene u društvu. Zbog njenog interdisciplinarnog karaktera, modifikacije koje je doživjela u relativno kratkom periodu mogu se usporediti s malim brojem drugih znanstvenih područja. Ovo područje je, stoga, jedno od najizazovnijih brojnim istraživačima koji pokušavaju dati svoj doprinos shvaćanju razvoja regija i razvoja uopće.

Regionalna, odnosno, kohezijska politika Europske unije glavna je investicijska politika Unije. Područja koja se pokušavaju unaprijediti kohezijskom politikom uključuju konkurentnost, gospodarski rast, održiv razvoj, stvaranje novih radnih mjesta i unapređenje kvalitete života, a sve u cilju smanjenja ekonomskih, socijalnih i teritorijalnih razlika među državama i regijama Unije. Ekonomsko uporište ovakvom opredjeljenju nalazi se u premisi da će razvijanje regija koje zaostaju u gospodarskom smislu doprinijeti rastu ukupnih performansi gospodarstva. Za ispunjenje ciljeva regionalne politike troši se gotovo trećina proračuna Europske unije kroz različite fondove, stoga se logički nameće pitanje opravdanosti i učinkovitosti regionalne i kohezijeske politike Europske unije u smislu ispitivanja postojanja realne konvergencije na razini regija.

Mogućnost postizanja regionalne konvergencije vrlo je privlačna ideja s ekonomskog aspekta, stoga ne čudi što zanimanje istraživača za ovu temu ne jenjava već desetljećima. Promijenom ekonomskih i nekih društvenih odnosa mijenjali su se i stavovi istraživača pa su tako nastajale i različite teorije o razvoju općenito, ali i o lokacijskim faktorima koji utječu na uspješnost regija. Teorijski ekonomski modeli gospodarskog rasta poslužili su kao svojevrsna osnovica za nastanak i razvoj teorija regionalnog razvoja koje regiju kao funkcionalnu jedinicu stavljaju u fokus istraživanja. Danas se regija promatra kao funkcionalna cjelina koja zahvaljujući određenim determinantama ima potencijal stvoriti sustav strukture pogodne razvoju, a determinante razvoja kreću se u rasponu od istraživanja i inovacija preko institucionalnih čimenika pa sve do specijalizacije regija kao determinante konvergencije, odnosno divergencije u nekim slučajevima.

## 1.1 Problem istraživanja

Unatoč naporima koji se ulažu i sredstvima kanaliziranim u rješavanje problema ekonomskih nejednakosti na regionalnoj razini u Europskoj uniji dispariteti i dalje egzistiraju. Interes istraživača za ovu temu utoliko ne jenjava. Usprkos brojnosti istraživanja koja se bave ovom problematikom, ona su raspršena na različite determinante konvergencije. Kada se debata o čimbenicima konvergencije suzi na koncepte koji gospodarsku strukturu uzimaju kao potencijalni objašnjavajući parametar ekonomskih dispariteta, odnosno konvergencije, ni tada nema zajedničkog stajališta. Dok je prema nekim autorima specijalizacija važan pokretač gospodarskog rasta regija (Storper, 2013., Storper, et al., 2015.), dio njih smatra kako diverzificirana struktura pruža veće mogućnosti za rast, ali i stabilnost (Hausmann, et al., 2013.). Autori koji zagovaraju tezu kako je diverzifikacija gospodarskih sekora, kao suprotnost specijalizaciji, poželjna karakteristika ekonomskih sustava argumentiraju da ona djeluje kao svojevrstan ublaživač u situacijama ekonomskih šokova, promjena u cijenama i produktivnosti određenih sektora, ali i da takvo okruženje pogoduje pojavi određenih pozitivnih eksternalija (Feldman i Audretsch, 1999.). Između tih krajnosti nalaze se autori koji zagovaraju određenu razinu specijalizacije. Primjerice, Farhauer i Kröll (2012.) uvode pojam „diverzificirane specijalizacije“ za koju smatraju da potiče međusektorska prelijevanja i umanjuje utjecaj šokova koji pogađaju određene sektore, što pogoduje rastu i stabilnosti u dugom roku. Slično, Frenken et al. (2007.) zagovaraju „povezanu raznolikost“ za koju smatraju da bi trebala dovesti do rasta zaposlenosti. Navedeno ukazuje na izostanak jedinstvenog stanovišta što proizlazi iz očite nedostatne istraženosti odnosa specijalizacije regija sa konvergencijom, odnosno gospodarskim rastom. Nadalje, ne postoji dovoljan broj sustavnih istraživanja koja su uspjela dokazati postojanje snažne korelacijske veze navedenog odnosa, naročito onih koja obuhvaćaju svih 28 zemalja članica Unije. Izneseni problem nastojati će se riješiti pregledom relvantnih teorijskih dostignuća i primjenom odgovarajućih analitičkih alata u empirijskom istraživanju kako bi se doprinijelo boljem shvaćanju razvojnih procesa kao nužnog preduvjeta za rješavanje problema regionalnih dispariteta.

Problem i predmet istraživanja mogu se jasno iščitati iz radne hipoteze, kao i iz pomoćnih hipoteza postavljenih na početku istraživanja:

**Radna hipoteza:** Realna konvergencija regija Europske unije uvjetovana je njihovom specijalizacijom.

**H1 –** Specijalizacija regija Europske unije utječe na razinu produktivnosti istih.

**H2 -** Razlike u produktivnosti među regijama rezultat su razlika u produktivnosti među sektorima njihovih specijalizacija.

**H3 –** Regije specijalizirane za financijske i poslovne usluge te regije specijalizirane u sektorima visoke dodane vrijednosti ostvaruju više stope rasta u odnosu na ostale regije.

**H4 –** Poljoprivredne regije i regije zastarijele industrijske proizvodnje ostvaruju niže stope rasta.

## 1.2 Svrha i ciljevi istraživanja

Cilj rada je istražiti vezu između realne konvergencije i specijalizacije regija. Regije specijalizirane u visoko produktivnim sektorima privlače visoko obrazovane radnike, viša su ulaganja u znanost i obrazovanje, takve industrije više kanaliziraju ulaganja u istraživanje i razvoj i dr.. Navedeni parametri generatori su dodane vrijednosti i visoke produktivnosti pa se opravdano smatraju čimbenicima razvoja, stoga se politike usmjerene na smanjenje regionalnih razlika primarno fokusiraju na njihovo unaprjeđenje kako bi se uklonile zapreke rastu i potaknula konvergencija. Da li je razvoj predeterminiran komparativnim prednostima, o čemu ovisi sektor specijalizacije neke regije i da li se obrasci specijalizacije mogu više ili manje uspješno preusmjeriti, a onda i upravljati procesom konvergencije, neka su od pitanja na koja će ovaj rad pokušati dati odgovor.

U radu će se regije podijeliti na određen broj skupina te će se analizirati zajednička obilježja među konvergirajućim, odnosno divergirajućim regijama. Iako svaka regija, neovisno o pripadnosti navedenim skupinama, ima svoje specifičnosti (prirodne, infrastrukturne, institucionalne, povijesne i dr.), zajedničke karakteristike unutar ovih skupina trebale bi ukazati i na određene zahtjeve po pitanju razvijanja djelotvornih politika za svaku od skupina. Analiza potreba regija, prema kojoj će se kasnije i kanalizirati sredstava u potrebita područja, svakako je ključni korak koji prethodi formuliranju rješenja za pokretanje rasta zaostajućih regija čime bi se s vremenom ostvarila konvergencija.

Obzirom na dosadašnja teorijska i empirijska dostignuća te sukladno podjeli regija koja će se primijeniti očekuje se dokazivanje teze o prisutnosti realne konvergencije kod država čije

regije su specijalizirane u sektorima visoke produktivnosti. Za zaostajuće regije analizirati će se čimbenici koji koče postizanje stopa rasta dovoljno visokih da sustignu razvijenije regije. Također, očekuje se postizanje doprinosa razumijevanju kauzalnosti odnosa gospodarske strukture s obzirom na sektore specijalizacije i ostvarenih ekonomskih performansi regija. Sustavni pristup koji, između ostalog, objedinjava mikroekonomske parametre, makroekonomske parametre i lokaciju kao mjesto aglomeriranja ekonomske aktivnosti trebao bi doprinijeti boljem razumijevanju procesa razvoja i konvergencije.

Svrha rada je istražiti vezu između realne konvergencije i specijalizacije regija i koji su to čimbenici na regionalnoj razini koji pogoduju optimalnom korištenju raspoloživih ljudskih i fizičkih resursa, odnosno ravnomjernom razvoja regija, a time i konvergenciji. Pri tom se prvenstveno misli na različite sektore specijalizacije regija koji, s obzirom na svoje specifičnosti, pružaju različite potencijale za ostvarivanjem napretka. U teorijskom smislu, očekuje se doprinos razumijevanju procesa konvergencije, procesa specijalizacije i navedenih procesa u međusobnoj interakciji. Razumijevanje veze ovih procesa, odnosno prepoznavanje zakonitosti među njima, do čega će se eventualno doći, omogućiti će u aplikativnom smislu podlogu za kvalitetnije sagledavanje stanja u gospodarstvu, prepoznavanje njegovih snaga i slabosti, što će uz predložen prognostički okvir biti platforma za učinkovitiju analizu i planiranje. Primjena je stoga moguća u kreiranju politika usmjerenih ka smanjivanju regionalnih nejednakosti, ali i u daljnjem istraživanju.

### 1.3 Ocjena dosadašnjih istraživanja

Regionalna ekonomija je znanstvena disciplina relativno novijeg datuma i razvijala se s obzirom na društveno ekonomske uvjete u datom trenutku. Pitanje neujednačenog ekonomskog i regionalnog razvoja u ekonomskoj teoriji, više ili manje naglašeno, prisutno je još od klasične ekonomske škole. Unutar klasične ekonomske škole, specijalizacija kao izvor rasta pojavljuje se još u Myrdalovoj teoriji kumulativne kružne uzročnosti (1957.), a s Novom ekonomskom geografijom revidira se u modelu jezgre-periferije (Krugman, 1991.) u kojoj prevlast centripetalnih, odnosno centrifugalnih sila dovodi do porasta, odnosno smanjenja razlika. U međuvremenu Kaldor (1970.) ukazuje na koristi ekonomije obujma koju regije mogu postići kako se specijaliziraju. Kolika korist će biti od specijalizacije ovisi o produktivnosti sektora specijalizacije. Detaljniji model razvili su Dixon i Thirlwall (1975.)

čija je glavna intencija bila uvesti kumulativnu uzročnost u model. Kumulativnost se očituje u tome što komparativna prednost određene regije čini regiju sve konkurentnijom pa se ona dodatno specijalizira u svojem izvoznom sektoru. Ovaj proces povratne veze (eng. *feedback effect)* djeluje u oba smjera na relaciji gospodarski rast – konkurentnost izvoznog sektora. Zajednički element svim teorijama i konceptima koji specijalizaciju ističu kao determinantu razvoja je trgovina. Trgovinska specijalizacija kao rezultat komparativnih prednosti datira još od Davida Ricarda (1817.). Iskorak u odnosu na Ricardov model dobio se uvođenjem drugog proizvodnog faktora (kapitala) u model u tzv. faktorsko-proizvodnom modelu (Heckscer-Ohlin-ov teorem) koji objašnjava način na koji se regije specijaliziraju. Model je višestruko testiran i potvrđen u SAD-u, dok primjerice rezultati istraživanja u UK pokazuju nešto manje uvjerljive rezultate. Modifikacije osnovnog modela doprinijele su boljem razumijevanju načina na koji se regije specijaliziraju.

Kako je rast izuzetno kompleksan proces, ambiciozno je očekivati da se svi čimbenici razvoja obuhvate jednom teorijom. Većina suvremenih pristupa regionalnom razvoju fokusira se na jedan ili nekolicinu njih (Capello, Nijkamp, 2009.). To su redom tehnologija i ljudski kapital (Romer, 1990., Scott, 1991. Krugman, 1991., Aghion i Howitt, 1992.,), umrežavanje, institucije, istraživanje i razvoj te inovacije (Grossman i Helpman, 1991., Aghion i Howitt, 1993., Cooke i Morgan, 1993., Romore 1999.), i dr. Teorijski koncepti u kojima se specijalizacija nalazi kao potencijalan izvor konkurentnosti nisu novost, međutim, postoje brojni radovi koji negiraju pozitivan utjecaj specijalizacije na dugorčni rast, ne dajući značaj sektorskoj strukturi gospodarstva za rast ili čak zagovaraju suprotno stajalište (Feldman, Audretsch, 1999.). Obzirom da znanost nema jednoznačan odgovor, a Europska unija se opredijelila za splet politika kojim podupire stajalište kako je specijalizacija relevantna za rast, zasigurno vrijedi ispitati tu tezu.

Teorijski koncepti koji izučavaju specijalizaciju počeli su se intenzivnije razvijati na osnovi koncepta komparativnih prednosti unutar trgovinskih teorija. Prema Kravisu (1971.) komparativne prednosti djeluju na skupinu proizvoda (sektora) i dolazi do specijalizacije i interindustrijske trgovine. Nadalje, zbog korištenja ekonomije obujma u proizvodnji dolazi do intraindustrijske trgovine. Pojava navedenih fenomena dovela je do velikog interesa teoretiča i istraživača koji su htjeli odgovoriti na pitanje u kojoj mjeri je razvoj gospodarstava determiniran specijalizacijom (Krugman, 1981., Balassa, 1986., Felvey, Kierzkowski, 1987., Greenaway et al., 1995.). Paralelno s razvojem trgovinske teorije, novi koncepti usmjereni na inovacije zauzimaju svoje mjesto u regionalnoj teoriji. Zajednička karkteristika ovih teorija su

različite eksternalije, odnosno, pozitivni učinci od grupiranja srodnih djelatnosti na određenoj lokaciji. U brojnim empirijskim istraživanjima izučavana je prostorna koncentracija industrija, a rezultati ukazuju da, neovisno i krištenim indikatorima, različite industrije pokazuju različite dinamike (Suedekum, 2006.; Dumais et al., (2002). Dorwick (1997.) unutar Nove ekonomske geografije razlikuje dva tipa pristupa. U prvom pristupu autori poput Batiz i Romera (1991.) i Rivera, Batiz i Xie (1993.) ističu kako zemlje koje se trgovinski otvore kroz specijalizaciju mogu ostvariti koristi iz ekonomije obujma s utjecajem na rast u dugom roku. U drugom pristupu zagovara se ideja kako su različite aktivnosti praćene različitom produktivnošću pa će gospodarstva zemalja specijaliziranim u sektorima više produktivnosti brže rasti. Primjerice Grossman i Helpmann (1991.) zaključuju da je produktivnost sektora specijalizacije u pozitivnoj korelaciji s rastom i kako se utjecajem na strukturu gospodarstva može potaknuti rast. Prema nekim autorima (Storper, 2013; Storper et al., 2015.) industrijska specijalizacija je glavni pokretač regionalnog ekonomskog rasta.

Rezultati empirijskih istraživanja konvergencije variraju ovisno o tome koja vrsta konvergencije[1] se razmatra, kojom metodologijom i na kojem području. Baumol (1986.) nalazi da zemlje s inicijalno nižom razinom BDP *per capita* ostvaruju više stope rasta što implicira postojanje procesa konvergencije. U brojnim radovima Barro i Sala-i-Martin (1991., 1992., 1995.) analizirali su konvergenciju regija u različitim zemljama. Pronađeno je postojanje apsolutne konvergencije za regije Sjedinjenih Američkih Država (48 saveznih država), Kanade (10 provincija), Japana (47 prefektura) i uvjetne konvergencije za regije nekih europskih zemalja (73 NUTS II regije). U promatranim zemljama regije su konvergirale po stopi od približno 2% što ukazuje na sporost procesa. Brojne studije kasnije nalaze postojanje uvjetne ili bezuvjetne konvergencije (Durlauf i Quah 1999., de la Fuente, 2000.). Le Gallo i Dall'erba (2005.) u analizu konvergencije uvode produktivnost sektora specijalizacije. Nalaze kako je konvergencija usko povezana s produktivnošću sektora

[1] U literaturi o regionalnom razvoju razlikuje se nekoliko vrsta konvergencija. Koncept beta konvergencije (β) potječe iz neoklasičnog modela, a odnosi se na proces u kojem nerazvijene ekonomije sustižu razvijene. Proces se događa zbog opadajućih prinosa na faktore proizvodnje, naročito kapital, uslijed čega nerazvijene zemlje (regije) rastu po višim stopama od razvijenih i s vremenom se smanjuju dispariteti u razinama BDP-a *per capita* i dohodaka. U dugom roku proces rasta će ekonomije dovesti u stanje ravnoteže u kojem je stopa rasta određena tehnološkim napretkom i stopom rasta populacije (radne snage). Kada se govori o zajedničkom ravnotežnom stanju kojem ekonomije teže, radi se o apsolutnoj konvergenciji. Međutim, ako se zbog određenih specifičnosti gospodarstava pretpostavi konvergencija koja ne previđa zajedničko stanje ravnoteže tada je riječ o uvjetnoj konvergenciji. Proces uvjetne konvergencije odnosi se na pojavu sustizanja razvijenih zemalja, pri čemu razine BDP *per capita* i stope rasta kojima ekonomije teže nisu nužno jednake. S druge strane, koncept sigma konvergencije (σ) nije baziran na procesu stustizanja nerazvijenih zemalja, već opisuje distribuciju dohotka (ili drugih pokazatelja) te razmatra smanjenje dispariteta među ekonomijama tijekom vremena.

specijalizacije i zaključuju da sektor poljoprivrede ostvaruje divergenciju, dok uslužni sektor ostvaruje konvergenciju. Izučavajući odnos specijalizacije i konvergencije Brenner i Kauermann (2016.) nalaze beta konvergenciju, ali i da se pojava konvergencija znantno razlikuje među industrijama u Njemačkoj. Rodrik (2012.) nalazi apsolutnu konvergenciju mjerenu produktivnošću rada u proizvodnji. Istraživanja na području Europske unije daju različite rezulatate ovisno o korištenim podatcima, vremenskim intervalima i primjenjenim statističkim alatima (Combes, Overman, 2003.). Primjerice, Marelli (2007.) na uzorku od 250 NUTS II regija Europske unije u periodu od 1980. do 2005. nalazi apsolutnu beta konvergenciju u *per capita* dohotcima, dok Giannone i Reichlin (2006.) zaključuju kako razlike u BDP-u *per capita* egzistiraju u zemljama Europe (i SAD) tijekom perioda od 1970. do 2003., uz određene iznimke, npr. Irske i Španjolske. Osim navedenih, brojni drugi autori su istraživali proces konvergencije, no ovisno o primjenjenoj metodologiji rezultati su nerijetko u suprotnosti, stoga se može zaključiti kako do danas nije postignut konsenzus na ovu temu.

## 1.4 Metode istraživanja

Sa ciljem potvrđivanja ili odbacivanja postavljenih hipoteza u radu se koriste brojne metode istraživanja u odgovarajućim kombinacijama. Uvodno će se najviše koristiti metode klasifikacije, deskripcije i komparacije kako bi se obradila teorijska osnova teme, kao i povijesni razvoj iste. Induktivnom i deduktivnom metodom te logičkim pristupom povezati će se teorija s postojećim istraživanjima. U empirijskom dijelu rada primjeniti će se odgovarajuće statističke i ekonometrijske metode u svrhu dokazivanja postavljenih hipoteza, analizirajući pri tom ponašanje varijabli poput dohotka *per capita* i proizvodnje među regijama u odnosu na gospodarsku strukturu regija s aspekta specijalizacije u pojedinim sektorima. Istraživanje će obuhvatiti prostor Europske unije na NUTS2 i NUTS3 razini regija. Glavni zaključci donijeti će se na osnovu panel analize rasta prema modelu uvjetne konvergencije. Rezultat istraživanja i komparacije teorije i empirije metodom sinteze biti će prikazan u vidu zaključka.

## 1.5 Kompozicija rada

U uvodnom dijelu definirani su problem istraživanja, svrha i ciljevi istraživanja te znanstvene metode korištene u radu. Navedene su i hipoteze čija će se istinitost testirati u empirijskom dijelu rada. Također su predstavljena dosadašnja istraživanja, a sukladno tome, i očekivani rezultati istraživanja. Uvodno je opisana i struktura rada te njegov znanstveni doprinos i moguća primjena.

Drugo poglavlje uvodi u temu predstavljanjem važnijih aktualnih teorija, ali i teorija koje su prethodile današnjem poimanju regionalnog razvoja, regionalnih nejednakosti i konvergenciji. Naročito će se obraditi teorije koje razmatraju konvergenciju, posebno regionalnu.[2] U sklopu ovog dijela predstaviti će se rezultati relevantnih empirijskih istraživanja na temu konvergencije s posebnim osvrtom na istraživanja fokusirana na konvergenciju regija. Paralelno s teorijom i empirijskim istraživanjuma prikazati će se praktičan pristup regionalnom razvoju, odnosno razvoj regionalne politike Europske unije koji je pratio važeća teorijska dostignuća u određenim povijesnim trenucima.

Trećim poglavljem obraditi će se teorijski aspekti specijalizacije regija kao faktora koji doprinosi postizanju realne konvergencije među regijama. Iako se elementi ovog pristupa nalaze i u starijim teorijama, primjerice onim baziranim na trgovini i izvozu, u ovom dijelu naglasak će biti na novijim teorijama koje su danas najzastupljenije i na čijim pretpostavkama je stvorena regionalna politika Europske unije kakvu danas poznajemo.

U četvrtom dijelu će se definirati očekivani odnos gospodarske strukture regija s obzirom na sektor specijalizacije i realne konvrgencije. Iz opisanog odnosa proizaći će konceptualan okvir na kojem će se bazirati empirijsko istraživanje. U ovom dijelu će se analizirati istraživačke hipoteze kojima će se pretpostaviti očekivani odnos elemenata predloženog modela na relaciji komparativne prednosti, gospodarska struktura, konvergencija.

U petom se dijelu, primjenom panel analize, testiraju hipoteze postavljene s obzirom na očekivane rezultate istraživanja. Osim toga, regije će se grupirati s obzirom na sektore specijalizacije kako bi se identificirale determinante razvoja, odnosno konvergencije. Za grupiranje regija primjeniti će se kriterij udjela broja zaposlenih i udjela bruto dodane vrijednosti po određenim sektorima. Regije s iznadprosječnim udjelima u određenim

[2] Dio teorija u kojima se nalaze osnovni elementi regionalne ekonomije bavile su nacionalnom razinom, iz čega proizlazi da su više ili manje primjenjive na regionalnu razinu.

sektorima biti će svrstane u kategorije prema sektoru specijalizacije. Ostale regije označiti će se kao regije bez posebnog sektora specijalizacije.

Konačno, u zaključnom dijelu, sustavno se predstavljaju najvažniji rezultati istraživanja, kao i eventualno odstupanje od očekivanih rezultata. Posljednji dio, ujedno je i svojevrstan osvrt na stanje u okruženju te kritički osvrt na aktualne politike Unije s obzirom na dobivene rezultate istraživanja.

# 2. TEORIJSKI KONCEPTI RELEVANTNI ZA FENOMEN KONVERGENCIJE

Teorija regionalnog razvoja razvijala se s određenim vremenskim zaostatkom u odnosu na ekonomsku teoriju. Razlog tome leži u činjenici što su početci suvremene ekonomske misli obilježeni vjerovanjem kako postoji savršen mehanizam, „nevidljiva ruka“ koja tržište dovodi automatizmom u stanje ravnoteže. Taj automatizam objašnjavao se slobodnom konkurencijom, mobilnošću faktora proizvodnje, fleksibilnošću cijena i nadnica i dr.. Regionalni razvoj, smatrao se političko-socijalnim pitanjem. S vremenom je, ipak, uočeno kako "automatizam" ponekad ima sklonost zakazati, a kako razlike među regijama egzistiraju. To je bila dovoljna motivacija teoretičarima i istraživačima da objasne tržišne anomalije i pokušaju pronaći rješenje za neuravnoteženost razvoja. „Vremenom regionalni razvoj postaje jedno od najatraktivnijih područja jer u sebi spaja ekonomske, prostorne, ekološke, nacionalne i druge momente“ (Osmanković, 2002.).

Kako bi se shvatio razvoj teorije regionalnog razvoja, korisno je podsjetiti se u kojem društveno-ekonomskom okruženju su nastajale. Svjetska gospodarska i politička scena sredinom prošlog stoljeća, nakon Drugog svjetskog rata, bila je obilježena brojnim turbulencijama. Razvijena gospodarstva 1950-ih i 1960-ih godina bila su karakterizirana masovnom proizvodnjom, radno i energetsko intenzivnim djelatnostima, regije su bile visoko specijalizirane, a njihova proizvodnja bila je prilično zaštićena protekcionisičkim državnim mjerama. Razdoblje 1970-ih donijelo je dramatične promjene u gospodarskom smislu, između ostalog i naftnu krizu. Gospodarstvo je tražilo način da se nosi s novonastalim promjenama. Uspješnije regije preorijentirale su se u znanjem-intenzivne tehnologije i došlo je do znatnog preslagivanja odnosa po pitanju razvijenosti. Liberalizacija svjetske trgovine, koja je uslijedila, razvijene nacije suočila je s nestabilnošću i globalnom konkurencijom. Kako su se nacije "otvarale" međunarodno, stvarale su se sve veće razlike između uspješnih i manje uspješnih regija i postajalo je sve jasnije kako se razvoj događa regionalno. (Stimson et al. 2006.)

S obzirom na opisana društveno-gospodarska zbivanja mijenjao se, naravno, i pogled na ekonomski razvoj i konvergenciju . U ovom dijelu rada, s obzrom na svrhu i cilj istraživanja, opisati će se relevantne ekonomske teorije koje su obilježile razvoj regionalne teorije te odnos pojedinog teorijskog pravca prema fenomenu konvergencije.

## 2.1 Neoklasični koncept rasta

Povijesno gledno, teorija regionalnog razvoja razvijala se tijekom 50-ih i 60-ih godina prošlog stoljeća. Iako se ne može govoriti o jedinstvenom pristupu, u ovom periodu istraživači su se bavili pitanjima ekonomskog rasta i pojave nejednakosti. Usprkos činjenici da su se autori dominantno bavili nacionalnim razlikama, principi se jednostavno mogu preslikati na lokalnu i regionalnu razinu stoga se ovaj period može smatrati začetkom teorije regionalnog razvoja.

Robert Solow 1956. godine razvio je model koji je trebao objasniti stilizirane činjenice rasta.[3] Ovaj model smatra se početkom moderne teorije rasta. Iako Solowljev model počiva na prilično spornim pretpostavkama, uspješno je objasnio činjenice rasta i svojedobno polučio izuzetan uspjeh i popularnost. Osnovni model, dakle, pretpostavlja proizvodnju jednog dobra u zatvorenom gospodarstvu (bez međunarodne razmjene) u kojem ne postoji država, već samo realni sektor, a tržište je okarakterizirano savršenom konkurencijom. Proizvedeno dobro može se upotrijebiti za potrošnju ili investicije. Prisutna je puna zaposlenost proizvodnih faktora proizvodnje, rada i kapitala čija je supstitutivnost endogeno određena. Tehnički napredak egzogeno je neutjelovljen, a tehnologija je javno dobro dostupno svima (Mervar, 1999.). Model je izveden iz dvije jednadžbe, neoklasične funkcije agregatne proizvodnje:

(2.1.) $Y_t = F(K_t), (L_t);$

i iz jednadžbe akumulacije kapitala:

(2.2.) $K_t = sY_t - \delta K_t.$

Funkcija proizvodnje karakteriziraju slijedeće osobine:

- *konstantni prinosi obujma* - povećanjem rada i kapitala po određenoj stopi, povećava se proizvodnja po istoj toj stopi
- *pozitivni opadajući prinosi* – povećanjem samo jednog od proizvodnih faktora, ukupna proizvodnja raste, ali po opadajućoj stopi.

Ponuda proizvodnih faktora određuje rast proizvodnje u kratkom roku, a proizvodnja po radniku i kapital po radniku konvergiraju u stanje ravnoteže, stanje u kojem se ne mijenjaju, stoga su izvori rasta akumulacija proizvodnih faktora i tehnološki napredak (Krueger, 2009).

[3] Ekonomist Nicholas Kaldor analizirajući podatke industrijskih zemalja uočio je postojanje određenih činjenica rasta. Objava stiliziranih činjenica potaknula je brojne rasprave među istraživačima, a rezultirala je i razvijanjem neoklasičnog modela rasta.

Dakle, Solowljev model dugoročni rast objašnjava uvođenjem tehnološkog napretka u funkciju proizvodnje. Svojim modelom Solow ne objašnjava izvor tehnološkog napretka, već se on "događa" izvan modela zbog čega je model prozvan *egzogenim modelom rasta.* Dok je u egzogenim modelima rasta naglasak na akumulaciji proizvodnih faktora, teorije nastale u narednom razdoblju fokusirale su se na objašnjenje izvora rasta, uvodeći rastuće prinose. Modeli nastali unutar tog teorijskog pravca nazivaju se *endogenim modelima rasta.*

Ključna ideja neoklasične teorije je da će u dugom roku doći do konvergencije kako se faktori proizvodnje mobiliziraju u prostoru. Prema neoklasičnom modelu, regije u kojima je granični proizvod rada viši imati će veće nadnice, a nizak povrat na kapital. To implicira kretanje rada i kapitala u suprotnim smjerovima. Dakle, regije s visokim graničnim proizvodom rada imati će neto priljev radne snage i neto odljev kapitala, dok će regije s visokim graničnim prozvodom kapitala imati neto priljev kapitala i neto odljev radne snage. Drugim riječima, regije s visokim dohotcima privlačiti će radnike i gubiti kapital i obratno, regije s niskim dohotcima imati će negativan migracijski saldo i priljev kapitala. S vremenom, prinosi na rad i kapital se izjednačavaju, a regionalne razlike smanjuju.

Bitno je razlikovati dvije osnovne kategorije konvergencije, beta i sigma konvergenciju.

Beta konvergencija[4] može biti apsolutna, odnosno bezuvjetna, kako se nekada naziva, a pojavljuje se jer je stopa rasta gospodarstva obrnuto proporcionalna udaljenosti ekonomije od njenog ravnotežnog stanja. Pretpostavka je da su parametri modela rasta jednaki za sve zemlje, što vodi tome da siromašnije zemlje (ili regije) rastu brže od bogatih i razlike se smanjuju dok se stope rasta ne izjednače Iako je tradicionalan neoklasični model razvijen da objasni razlike među zemljama, ove pretpostavke primjenjivije su na regionalnoj razini jer su određene karakteristike regionalnih gospodarstava homogenije, nego među različitim zemljama. S druge strane, regije su otvorenije s obzirom na trgovinu, a pretpostavka neoklasičnog modela je zatvorenost privrede. Prebacujući se na regionalnu razinu, istraživači pokušavaju objasniti implikacije interregionalne razmjene. Inrerregionalni tijekovi rada i kapitala determinirani su diferenciranim stopama povrata. Pretpostavka neoklasičnog modela je da su granični prinosi na kapital viši u regijama s nižim odnosom kapitala po jedinici rada, a grančni prinos na rad je viši u regijama s većim odnosom kapitala po jedinici rada. Obzirom da među regijama nema ograničenja na kretanje proizvodnih faktora, kapital će odlaziti u

[4] Koeficijent β označava brzinu kojom ekonomije konvergiraju u postojano stanje.

regije s niskim odnosom kapitala po jedinici rada, a radna snaga u suprotnom smjeru. Na taj način gospodarstvo se kreće prema postojanom stanju (Magrini, 2003.).

U regresijskoj analizi apsolutna konvergencija opisuje se jednadžbom:

(2.3.) $\hat{Y}_t = \alpha_0 + \beta Y_o + \varepsilon$;

Pri čemu je $\hat{Y}_t$ godišnja stopa rasta, a $Y_o$ početana vrijednost produktivnosti rada ili dohotka. Koeficijent $\beta$ ima negativnu vrijednost.

Neoklasični model predviđa da zemlje koje su bliže svojoj stazi ravnomjernog rasta rastu sporije i obrnuto. Uvjetna konvergencija zbog razlika među zemljama (u stopama rasta populacije, stopama štednje, institucionalnom okruženju i dr.) ne predviđa zajedničku (apsolutnu) stazu rasta za sve, već svaka zemlja ima svoju individualnu stazu ravnomjernog rasta kojoj teži, koje se razlikuju među zemljama. Realnije je, stoga, očekivati da svaka zemlja konvergira prema svojoj stazi ravnomjernog rasta. Uvjetna konvergencija, dakle, mnogo bolje opisuje stvarnost od apsolutne konvergencije. Iz tog razloga istraživači su mnogo više usmjereni na uvjetnu konvergenciju. Stanje kojem zemlje konvergiraju karakterizirano je konstantnim odnosom kapitala po jedinici rada, potrošnjom i dohotkom *per capita* (Dawkins, 2003.).

Regresijska jednadžba kojom se opisuje uvjetna konvergencija glasi:

(2.4.) $\hat{Y}_t = \alpha_0 + \beta Y_o + Y'\phi + \varepsilon$;

Pri čemu $\phi$ predstavlja kontrolnu varijablu kojom se opisuje individualna putanja rasta. Može se odnositi na tehnologiju, ljudski kapital, stopu štednje, amortizaciju i drugo.

S druge strane, koncept sigma konvergencije (σ) ne razmatra proces sustizanja manje razvijenih zemalja (regija) razvijene već se bavi smanjenjem dispariteta među regijama. Dva pojma su usko povezana, beta konvergencija je nužna, ali ne i dovoljna za sigma konvergenciju. U stvarnosti zemlje mogu beta konvergirati, ali zbog različitih šokova međusobno se udaljavaju (Young, et al. 2008.).

Mjere koje se koriste za ispitivanje sigma korvengencije uključuju: Ginijev koeficijent, Atkinsonov indeks, Theilov indeks i dr. (Monfort, 2008.). Zajedničko ovim pokazateljima je to da svi mjere nejednakosti u dohotcima.

Unutar neoklasične doktrine određeni značaj za opisivanje načina na koji se regije specijaliziraju može se pripisati se faktorsko-proporcionalnom, odnosno Heckscher-Ohlinovom modelu (HO). Prema ovom dvofaktorskom modelu regije će se specijalizirati u proizvodnji onih dobara za čiju proizvodnju imaju prednost u dostupnosti faktora proizvodnje, rada ili kapitala. Primjerice, regije koje obiluju kapitalom specijalizirati će se u kapitalno intenzivnim djelatnostima. Iako model počiva na prilično rigoroznim i spornim pretpostavkama, naročito na regionalnoj razini, poslužio je kao osnova za razvoj nekih suvremenijih teorija.

## 2.2 Koncept endogenog rasta

Najizraženiji nedostatak neoklasičnog egzogenog modela rasta je činjenica da tehnološki napredak nije objašnjen modelom. Pretpostavka egzogeno određene stopa tehnološkog rasta, korištena iz analitičkih razloga, rezultirala je činjenicom da najvažniji faktor, onaj koji generira rast, u modelu ostaje nepoznanica (Romer, 1993.). Unatoč očitom nedostatku i naporu brojnih autora da premoste ovaj problem, egzogenost se zadržala u endmodelima sve do sredine 80-ih godina. Doprinos endogenih modela je determiniranje dugoročnog rasta unutar modela. Temelji endogene teorije rasta nalaze se u radovima Romera (1986., 1990.) te kasnijim doprinosima Lucasa (1988.), Grossman i Helpmana (1991.) i Aghion i Howitta (1998.).

Endogeni koncepti rasta nastali su na kontroverzi konvergencije i nekim činjenicama koje su prisutne u realnim ekonomskim sustavima, a bile su zanemarene u egzogenim modelima. Jedna od tih činjenica je da tehnološki napredak proizlazi iz određenih procesa, odnosno aktivnosti, bilo da se radi o istraživanjima ili ukupnoj ekonomskoj aktivnosti. Promjena u odnosu na neoklasični model je preferiranje monopolističke konkurencije koja omogućava ostvarivanje ekstra profita (monopolske rente). Drugim riječima, bilo je potrebno stvoriti alternativu pretpostavci savršene konkurencije (Romer, 1994.). Pojedinci i poduzeća imaju određenu kontrolu nad svojim otkrićima, što ih čini isključivim i nedostupnim, a ne javnim dobrima kao ranije i to im omogućava internalizaciju njihovih ulaganja (Gleaser et al., 1992.).

Endogeni modeli koriste prelijevanje znanja i kapitala za eliminiranje opadajućih prinosa. Naglasak je na ljudskom kapitalu, čijom se akumulacijom, odnosno, akumulacijom znanja ostvaruje rast. Ljudskom kapitalu priznaje se važnost i za poduzeća i za gospodarstvo, stoga

se ukazuje na obrazovanje kao bitnu komponentu razvoja. Obrazovana radna snaga, osim što ima veći apsorpcijski kapacitet za usvajanje novih tehnologija, ona je sposobna i proizvesti inovacije i novu tehnologiju pa je utoliko i produktivnija. Eksternalije u obliku difuzije znanja poznate su kao Marshall-Arrow-Romer (MAR) eksternalije. One se događaju među poduzećima na koncentriranom geografskom području obilježenom lokalnim monopolima. Uloga države je balansiranje između poticanja difuzije znanja i stvaranja institucionalnog okruženja koje pogoduje razvoju inovacija (patenti, zaštita intelektualnog vlasništva).

Generatori razvoja unutar endogenih teorija rasta jesu istraživanje i razvoj, inovacije, ulaganje u znanje i obrazovanje i prelijevanje znanja i tehnologija. Unutar ovih koncepata sugerira se pozitivna korelacijska veza između jaza u tehnologiji i rasta produktivnosti (Armstrong i Taylor, 2000.). Uspješne ekonomije predvode u razini tehnologije i inovacijama, a manje uspješne trebaju iskoristiti njihova znanja za napredak u produktivnosti i tako eventualno s vremenom konvergirati (Magrini, 2003.).

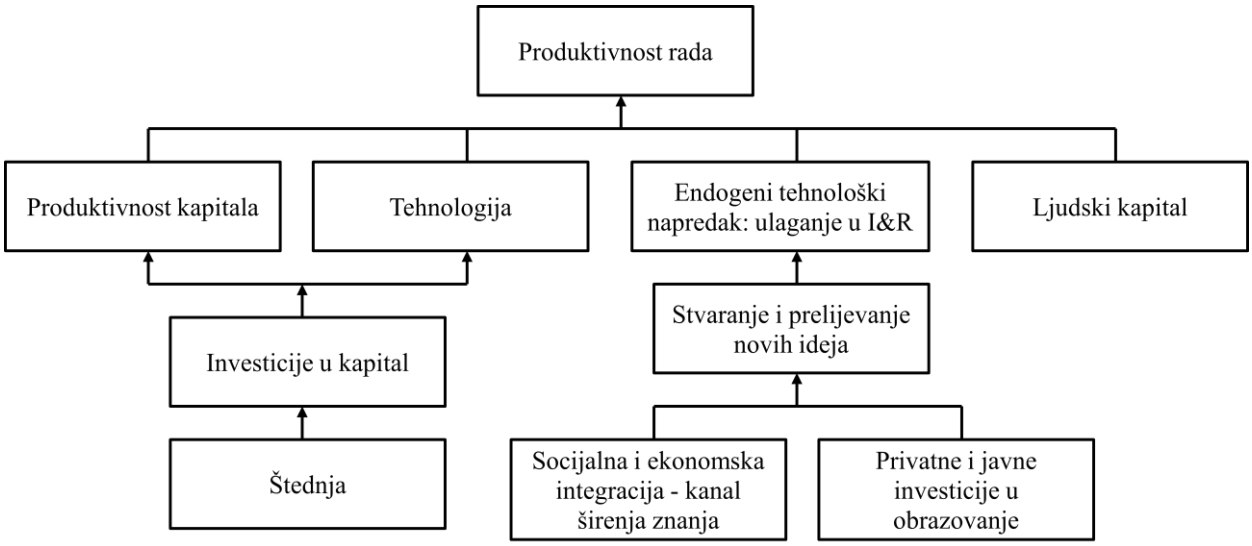


**Grafički prikaz 1: Determinante produktivnosti rada**

Izvor: Prikaz autra prema Armstrong, H., Taylor, J. (p.88, 2005.)

Unutar endogenog koncepta rasta, uslijed djelovanja opadajućih prinosa na kapital, razine *per capita* dohodaka trebale bi konvergirati prema vrijednosti dohotka ravnotežng stanja, a brzina konvergencije raste zajedno s udaljenosti vrijednosti dohotka od ravnotežnog stanja. Drugim riječima, za regije s inicijalno nižom vrijednosti dohotka *per capita* očekuje se da će generirati više stope rasta (Aghion i Howitt, 2009.)

Iz perspektive ovog rada potrebno je razmotriti odnos endogenih koncepata i sektorske strukture regija. Ethier (1985.) naglašava kako specijalizacija u proizvodnji pogoduje korištenju ekonomije obujma. Romer (1986.) na tragu ove ideje razvija model koji objašnjava kako specijalizacija u proizvodnji pogoduje rastu ukupne ekonomske aktivnosti. Prema Porteru (1990.) okruženje pogodno difuziji znanja jesu specijalizirane industrije na ograničenom geografskom području.

Zaključno, koncept endogenog rasta teško se može smatrati jedinstvenim pristupom jer su determinante rasta diverzificirane ovisno o promatranim autorima. Međutim, pomaci u odnosu na neoklasičan koncept rasta u vidu monopolističke konkurencije, objašnjenja tehnološkog progresa, ljudskog kapitala, efekata prelijevanja i dr. predstavljali su znatan pomak teorije prema stvarnosti. Stoga su neke ideje iz ovog perioda i danas aktualne.

## 2.3 Koncept izvozne baze

Jedan od glavnih nedostataka neoklasične ih i endogenih koncepata rasta je zanemarivanje potražne strane ekonomija. Na toj osnovi nastao je jedan od najpopularnijih koncepata koji su se uhvatili u koštac s regionalnim disparitetima. Izvozno orijentirane koncepti rasta nastali su 1950-ih godina. North (1955.) u svom radu tvrdi kako je razvoj regije determiniran njenom sposobnošću da odgovori na egzogenu izvoznu potražnju. Početni impuls izvozu je prirodno bogatstvo kojim regija raspolaže. Taj argument, u nekim slučajevima, može se koristiti za objašnjavanje razlika u stopama rasta (Armstrong i Taylor, 2005.). Regije se s vremenom specijaliziraju kako bi odgovorile na izvoznu potražnju koja postaje glavni generator razvoja. Nadalje, North ističe kako regije na višim razinama razvoja gube svoju specijalizaciju obzirom da zbog porasta dohotka raste rezidencijalna potražnja za svim vrstama dobara i usluga, a isto se događa i s izvoznom bazom. S gubitkom specijalizacije i mobilnošću faktora proizvodnje, kao i u Heckscher-Ohlinovom faktorski-proporcionalnom (HO) modelu, proizvodnja se disperzira kroz zemlju i postiže se međuregionalna konvergencija (Dawkins, 2003.).

U osnovnom modelu ekonomija je podijeljena na izvozni i lokalni sektor, pri čemu je izvozni sektor generator je razvoja. Funkcija izvozne potražnje ima oblik:

(2.5.) $X^d = f(P_x, Z, P_s)$;

Izvozna potražnja, dakle, determinirana je cijenom izvoznih proizvoda ($P_x$), razinom dohotka u drugim regijama ($Z$) i cijenom supsituta u drugim regijama ($P_s$).

Strana ponude izvoznog sektora određena je odnosom cijena proizvodnih faktora i razinom tehnologije i ovisno o troškovnoj učinkovitosti, regija će biti više ili manje uspješna:

(2.6.) $X^s = f(P_x, W, P_k, R, C, T)$;

Izvozni sektor na strani ponude određen je odnosom cijene izvoznih proizvoda ($P_x$), visinom nadnica ($W$), troškom kapitala ($P_k$), troškom sirovina ($R$), troškom intermedijarnih proizvoda ($C$) i razinom tehnologije ($T$).

Konkurentnost regije, zbog fleksibilnosti cijena, podložna je promijenama. Rast potražnje za izvozom prati porast cijena proizvodnih faktora. Ekspanzija izvozne potražnje stoga može rezultirati u dva scenarija. Ukoliko zbog porasta cijena proizvodnih čimbenika regija ne uspije održati konkurentnost, prilagodbom produktivnosti ili dr., izvozna potražnja preusmjeriti će se u druge regije i dolazi do konvergencije. S druge strane, regija može zadržati konkurentnost na način da poboljša produktivnost ili se, uvođenjem novih proizvoda, proširi na nova izvozna tržišta.

Obzirom da rast ima obilježje kumulativnosti moguće su dodatne dvije pojave. Gospodarski razvoj može djelovati kao poticaj za privlačenje novih investicija, a porast dohodaka rezultirati migracijom radne snage. Prvo se može iskoristiti za stvaranje ekonomije obujma kao i drugih prednost iz aglomeriranja ekonomskih aktivnosti, čime izvozni sektor može dodano ojačati. Potonje rezultira dodatnim porastom lokalne potražnje i slijedom toga, dodatnim osnaživanjem ekonomije (Armstrong i Taylor, 2005.). Ukoliko uspješnije regije uspiju iskoristiti ove mogućnosti doći će do održavanja divergencije.

Kako se regije razvijaju, a uslijed rasta dohodaka raste i potražnja za diverzificiranim proizvodima, a kako bi regije odgovorile na potražnju, diverzificira se i proizvodnja. Zbog mobilizacije proizvodnih čimbenika i rastuće diverzifikacije izvozne baze regija, tijekom vremena proizvodnja se disperzira među regijama, a regionalni dohotci konvergiraju (Dawkins, 2003.).

Konceptu izvozne baze, u njegovoj najjednostavnijoj inačici, kritičari zamjeraju presimplifikaciju stvarnosti, između ostalog, zanemarivanje mobilnosti faktora prozvodnje što

je posebno naglašeno na regionalnoj razini gdje ne postoje trgovinske i druge barijere. Dodatne kritike teoriji izvozne baze usmjerene su na zanemarivanje institucionalnih čimbenika, uloge vlasti, poduzetničke klime i sl. Međutim, glavna zamjerka je egzogenost izvozne potražnje čije ponašanje nije objašnjeno, što ovaj model čini nepodobnim za korištenje u prognostičke stvrhe (Armstrong i Taylor, 2005.). Unatoč činjenici da je teoretski kritiziran, ovaj koncept doživio je brojne modifikacije i prilično se dugo zadržao u teoriji regionalnog razvoja.

## 2.4 Koncept polova rasta

Glavni predstavnici teorije polova rasta Perroux (1950.) i Hirschman (1958.) objasnili su zbog čega se razvoj događa neravnomjerno u prostoru, koncentrirajući se u polovima razvoja, najčešće urbanim aglomeracijama koje osim navedenog koriste infrastrukturne prednosti, kao i prednosi blizine tržišta (Osimanković, 2002.). Začetnik teorije polova rasta Perroux (1950.) prostor vidi kao mrežu interakcija prožetih centripetalnim silama. Autor polove rasta povezuje sa odnosom poduzeća i industrija. Propulzivna poduzeća (eng. *propulsive firms*), ona poduzeća relativno veća u odnosu na ostale, generiraju inducirani rast kroz interindustrijske veze dok agregatna proizvodnju raste. Slično, Hirschman (1958.) opisuje veze prema naprijed (eng. *forward linkages*) i veze prema natrag (eng. *backward linkages*) između poduzeća. Prve uzrokuju kretanje prema lokacijama postojeće aktivnosti što može prouzrokovati učinak talasanja (eng. *backwash effect*) kada polovi rasta privuku toliko aktivnosti da se učinci počinju širiti na okolna područja. Potonje se povezuju s aktivnostima u kojima se proizvode inputi za gospodarsku djelatnost i kreću se prema lokacijama na kojima se nalazi velik broj kupaca. Migracije radnika kreću se u smjeru polova rasta uzrokujući daljnju polarizaciju rasta i ograničavajući rast u drugim područjima (Capello i Nijkamp, 2009.). Autor navodi kako od polariziranog razvoja imaju koristi i rastuće regije i njihova okolna područja. Poput Myrdalovih učinaka „širenja“ (eng. *spread effects*) i „talasanja“ (eng. *backwash effects*), Hirschman tvrdi da razvijene regije proizvode povoljan učinak „slijevanja“ (eng. *„trickling-down“ effect*) na regije koje zaostaju obzirom da se u razvijenim regijama kupuju dobra proizvedena u zaostajućim regijama. S druge strane, nepovoljan učinak „polariziranja“ (eng. „*polarization“ effect*) može proizaći iz konkurencije i trgovinskih barijera unutar razvijenih regija.

Boudeville (1966.) daje Perrouxovoj formulaciji geografsku dimenziju. Autor polove rasta definira kao prisutnost propulzivnih poduzeća i industrija koji u svojoj interakciji generiraju kontinuiran rast preko veza s drugim poduzećima u regiji.

Usporedno s konceptom polova rasta, nastajala je teorija kumulativne kružne putanje razvoja. Ovaj teorijski pravac naglašava odnos ponude i potražnje, ali i političke i institucionalne faktore razvoja. Koncept polova rasta Myrdalovoj teoriji kumulativne uzročnosti dodaje prostornu dimenziju. Gunnar Myrdal (1957.) zapaža da postojanje ekonomije obujma dovodi do grupiranja ekonomske aktivnosti u regijama koje se prije industrijaliziraju. Takve regije ostvaruju rast kroz međuregionalnu trgovinu. Osim toga, rast se produbljuje procesom kumulativne uzročnosti. Iako nerazvijene regije imaju prednost u niskim nadnicama, ona nije dovoljna da sustigne putanju rasta razvijenih regija pa se nejednakosti se produbljuju zbog toga što faktori proizvodnje, kapital i rad, imaju tendenciju seliti u razvijenije regije. Slobodna trgovina među regijama produbljava navedene probleme. Iako manje razvijene regije u tom procesu ostvaruju određene benefite, poput preljevanja znanja i inovacija, ovi učinci nisu dostatni da se razlike među regijama eliminiraju (Dawkins, 2003.). Dapače, prema ovom pristupu, razlike u stopama rasta u konačnici dovode do divergencije među regijama (Harris, 2008.).

Sličan koncept ponudio je Friedman (1966.) u modelu centar-periferija (eng. *center-periphery*) u kojem uključuje elemente Myrdalove teorije neuravnoteženog regionalnog rasta i teorije izvozne baze iz koje preuzima mogućnost eksterno induciranog rasta. Također, autor naglašava utjecaj međuregionalnih migracija na konvergenciju. Velika urbana područja, prema ovom modelu, imaju inicijalnu prednost pred konkurencijom za daljnji rast kroz opadajuće troškove. Ovi i ostali čimbenici idu u prilog urbanim aglomeracijama koji predvode u rastu. Ruralna područja su u zamci strukturnog siromaštva, prvenstveno zbog njihove strukturne ovisnosti o razvijenim regijama.

S aspekta regionalne teorije i razvojnih dispariteta najznačajnije je zapažanje nelinearnosti odnosa nacionalnog i regionalog rasta. Koristeći argumente Kuznetsa (1955.), Myrdala (1957.) i Hirschmana (1958.), prema kojima razvojni obrasci idu u prilog glavnim aglomeracija, Williamson (1965.) je zapazio da ekonomije slijede određene obrasce ponašanja prema kojima zemlje u početnim stadijima razvoja ostvaruju regionalnu divergenciju, dok se na višim razinama razvoja regionalne razlike smanjuju. Williamson preuzima Kuznetsov pristup objašnjavanja rasta nejednakosti među kućnastvima u ranim fazama procesa

konvergencije kojeg zamjenjuje obrat, odnosno smanjenje nejednakosti u kasnijim fazama. Kuznetsovoj krivulji oblika obrnutog „U“ Williamson dodaje prostornu dimenziju i koristi je za objašnjavanje pojave regionalnih dispariteta (Davies i Hallet, 2002.).

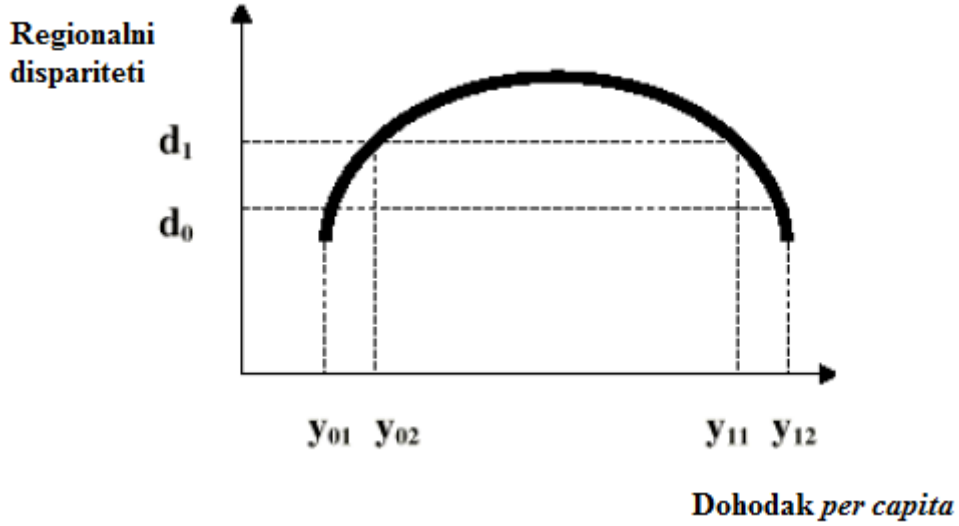


**Grafički prikaz 2: Williamsonova krivulja**

Izvor: prikaz autora prema Davies i Hallet (2002.)

U argumente koji idu u prilog ovoj tezi ubraja se zapažanje ekonomista ovog vremena da se rast, zbog određenih lokacijskih prednosti, događa na ograničenom broju gospodarskih žarišta, u tzv. polovima rasta koji koriste komparativne prednosti za stvaranje ekonomije obujma, ali i stvaraju određene tržišne nesavršenosti koje generiraju neuravnotežen razvoj u prostoru.

Koncept postojanja učinka trgovine (engl. *trade off*) između jednakosti i učinkovitosti, odnosno nacionalnog rasta i regionalne konvergencije, zadržao se kroz teoriju regionalnog razvoja unutar tzv. mainstream teorija, nove endogene teorije i nove ekonomske geografije, a i empirijski je višestruko potvrđen (Davies i Hallet, 2002.).

## 2.5 Koncept kumulativne uzročnosti

Unutar izvozno orijentiranih koncepata jedna od najznačajnijih hipoteza koje objašnjavaju divergenciju je kumulativna uzročnost gospodarskog razvoja. Ovaj koncept datira još od

Myrdala (1957.) koji tvrdi da rastući povrati na obujam pridonose aglomeriranju ekonomske aktivnosti u onim regijama koje se prve industrijaliziraju, a proces gospodarskog rasta dodatno je potaknut procesom kružne kumulativne uzročnosti. Iako manje razvijene regije imaju nominalno niže nadnice i ostvaruju određene koristi kroz učinak „širenja“, rezultat kojeg je difuzija tehnologije i inovacija, ovi učinci nisu dovoljni da anuliraju prednosti nastale u industrijaliziranim ekonomijama i postignu konvergenciju. Dodatna divergencija nastaje zbog učinka „talasanja“ uslijed kojeg kapital i radnici napuštaju manje razvijene regije.

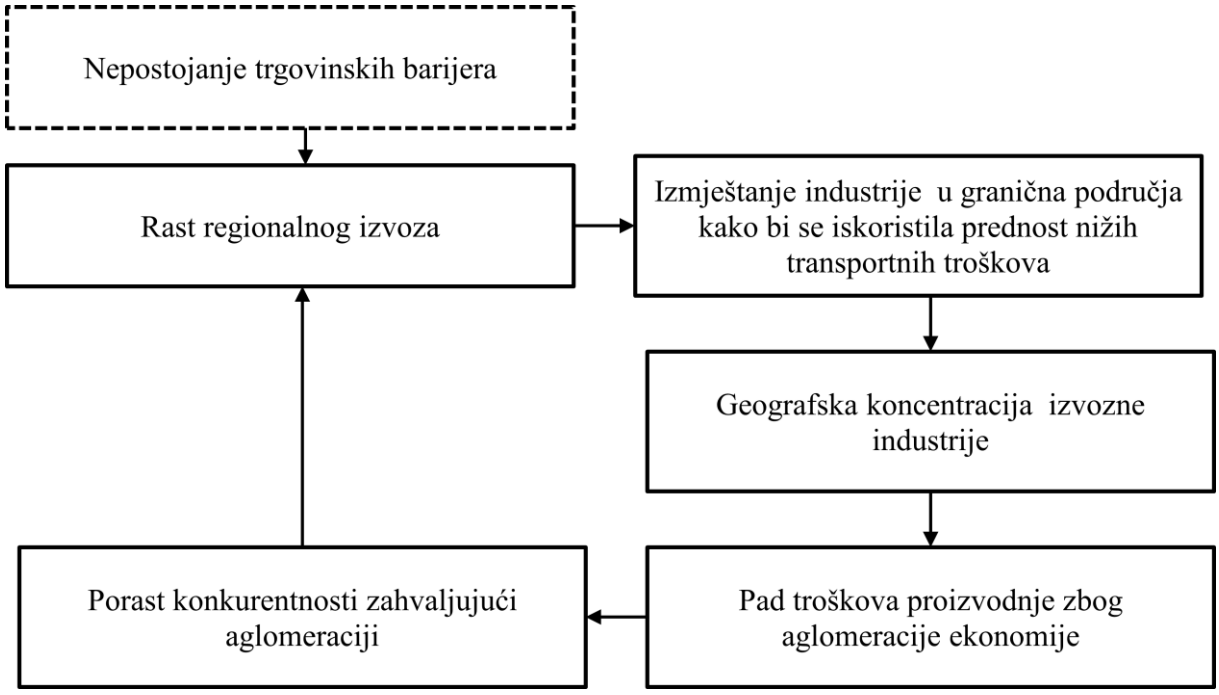


**Grafički prikaz 3: Aglomeracijska ekonomija i kumulativna uzročnost**

Izvor: Prikaz autora prema Armstrong i Taylor.(2005)

Kaldor (1970.) iz Myrdalove teorije zadržava prednost regije koja se prva industrijalizira i uvodi u teoriju kumultivne uzročnosti produktivnost. Myrdalova teorija bila je usmjerena više na sociološke elemente ekonomije, dok se Kaldor fokusirao na kumulativnu kauzalnost odnosa ponude i potražnje (O'Hara, 2009.). Prema njegovoj teoriji, regije će biti uspješne u onoj mjeri u kojoj uspiju iskoristiti prednosti koje proizlaze iz specijalizacije, između ostalog i ekonomiju obujma. On uspostavlja distinkciju između produktivnijih i manje produktivnih sektora. Kaldor tvrdi da su proizvodni, industrijski sektori uspješniji u postizanju

produktivnosti i stoga je razvojni proces regija određen njihovom sektorskom strukturom. Kako industrijske regije ostvaruju bolji ekonomski rezultat, još više uvoze proizvode iz neproizvodnih regija, a rezultat je dodatno produbljavanje specijalizacije. Kaldorova teorija bazira se na nekoliko propozicija:

- Rast regije određen je rastom izvoza,
- Rast izvoza ovisi o cjenovnoj konkurentnosti regije i porastu dohotka drugih regija,
- Promijene cijena u regiji ovise o razlici između rasta nadnica i rasta produktivnosti,
- Porast produktivnosti rada dijelom je određen rastom agregatnog proizvoda kroz rastuće prinose (obuhvaćeno Verdoornovim zakonom[5]).

Najvažnija odrednica regionalnog rasta je izvoz koji je egzogena komponenta agregatne potražnje, dok su potrošnja i investicije determinirane samim gospodarskim rastom. Specijalizacija na razini regije doprinosi rastu izvoza.

Glavne zamjerke Kaldorovoj teoriji usmjerene su na unaprijed određen razvojni put regija (eng. *path dependency*) prema kojem se divergencija među njima produbljava bez mogućnosti obrata (Thirlwall, 2013.).Usprkos tome, njegove teze bile su inspiracija brojnim teoretičarima.

Na tragu ove ideje Dixon i Thirlwall (1975.) razvili su formaliziran model koji otklanja navedeni nedostatak i predviđa mogućnost regionalne konvergencije. Njihov model kumulativnog rasta sastoji se od:

(2.7.) $g_{it} = yx_{it}$

(2.8.) $x_{it} = \eta(p_{it} - p_{ft}) + \varepsilon z_{ft}$

(2.9.) $p_{it} = w_{it} - r_{it} + \tau_{it}$

(2.10.) $r_{it} = r_{a,i} + \lambda_i g_{it}$

Prva jednadžba odnosi se na hipotezu izvozno determiniranog rasta regije $i$ prema kojoj je stopa rasta gospodarske aktivnosti regije ($g_{it}$) funkcija rasta izvoza regije ($x_{it}$). Drugom jednadžbom objašnjen je rast regionalnog izvoza koji je određen relativnom promjenom cijena: domaćih ($p_{it}$) i inozemnih ($p_{ft}$) te cjenovnom elastičnošću izvozne potražnje ($\eta$),

[5] Verdornov zakon odnosi se na pozitivnu korelacijsku vezu između rasta proizvodnog sektora i produktivnosti proizvodnog sektora.

($\eta < 0$), kao i svjetskom potražnjom pri čemu je $\varepsilon$ dohodovna elastičnost izvoza ($\varepsilon > 0$), a $z_{ft}$ je stopa rasta svjetskog dohotka. Kada je $\varepsilon$ veći regija će imati veći rast izvoza u odnosu na druge regije. Trećom jednadžbom obuhvaćena je strana ponude, odnosno stopa rasta domaćih cijena ($p_{it}$) kao funkcija rasta domaćih nadnica ($w_{it}$), rasta produktivnosti rada ($r_{it}$) i stope promjene profitne marže u proizvodnji ($\tau_{it}$). Četvrtom jednadžbom obuhvaćeno je djelovanje Verdoornovog zakona, dugoročne pozitivne veze između produktivnosti i gospodarske aktivnosti, pri čemu je rast produktivnosti u regiji ($r_{it}$) određen egzogeno determiniranom komponentnom rasta produktivnosti ($r_{a,i}$) i rastom gospodarske aktivnosti regije ($g_{it}$). Verdoornov koeficijent ($\lambda$) odnosi se na mjeru u kojem stupnju se rast gospodarske aktivnosti reflektira na porast produktivnosti.

Kada se jednadžbe (2.8.)-(2.10.) supstituiraju u (2.7.) dobije se izraz:

(2.11.) $g_{it} = y\left[\eta\left(p_{it} - p_{ft}\right) + \varepsilon\left(z_{ft}\right)\right]$

Odnosno, ravnotežna stopa rasta je:

(2.12.)

$$g_{it}^{*} = y\frac{\left[\eta\left(w_{it} - r_{a,it} + \tau - p_{ft}\right)\right]}{1 + y\eta\lambda_i}$$

Prema ovom konceptu rast produktivnosti i gospodarskih aktivnosti rezultira kumulativnim procesom u kojem se zahvaljujući korištenju ekonomije obujma stvara cjenovna prednost rezultat koje je rast tržišnog udjela. Regije sa rastućim proizvodnjom i izvozom na taj način stječu kumulativnu konkurentsku prednost nad sporije rastućim regijama. Slijedom navedenog, model omogućava egzistiranje nejednakosti, čak i njihovo produbljavanje, ovisno o vrijednostima parametara modela.

Nedostatci modela, između ostalog, očituju se u sljedećem (Ciriaci, 2004.):

- Pretjerano oslanjanje na cjenovnu konkurntnost zanemarujući ostale čimbenike;
- Egzogeno determinirani dohotci;
- Zanemarivanje povijesnih činjenica ekonomija što ga čini nekonzistentnim s Kaldorovom teorijom s aspekata povijesnog determinizma i njegovih kritika teorijama;
- Zanemarivanje ograničenja bilanci plaćanja;
- Zanemarivanje gospodarske strukture.

Iz perspektive ovog rada posebno je relevantna činjenica da model zanemaruje gospodarsku strukturu regija i način na koji se regije specijaliziraju. U osnovnom modelu svi ne-cjenovni parametri (uključujući sektorsku strukturu) obuhvaćeni su dohodovnom elastičnošću izvoza. Amable i Verspagen (1995.) nalaze da različite industrije u strukturi izvoza imaju difrencirane stope elastičnosti. Prema Pasinettiju (1981.) različite stope rasta među industrijama određuju specijalizacijske obrasce, a onda i ukupne stope rasta. Neki autori, primjerice Fiorillo (1997.), pokušali su premostiti navedeni nedostatak na način da su formuliraju modele koji se baziraju na uzajamnom odnosu specijalizacije i rasta: sektorska specijalizacija determinira rast, a rast uvjetuje sektorsku specijalizaciju. Prema njegovom modelu, ekonomije konvergiraju u stanje srednjoročne ravnoteže karakterizirane konstantnom sektorskom strukturom i stopama rasta, a rezultat je uvelike određen razvojnom putanjom (eng. *path dependency*).

## 2.6 Koncept Nove ekonomske geografije

Nova ekonomska geografija proizašla je iz trgovinskih teorija nastalih 1970-ih i 1980-ih godina. Prije toga trgovina je shvaćana kao rezultat razlika u resursima i komparativnih prednosti. Kroz tu prizmu poimali su se i obrasci specijalizacije. Zajedničko obilježje svim teorijama od Smitha do 1970-ih bilo je vjerovanje da se trgovina događa među gospodarstvima međusobno različitih struktura. Moderna trgovinska teorija pokušala je objasniti izvore intraindustrijske trgovine i dominaciju trgovine među razvijenim zemljama što se nije uklapalo u dotad opće prihvaćen Heckscher-Ohlin model.[6] Napuštajući pretpostavku konstantnih prinosa na obujam uvođenjem ekonomije opsega, kao i nesavršene konkurencije, otvorio se prostor za stvaranje mikroekonomskog bihevioralnog modela, nove ekonomske geografije (p. 67, Capello i Nijkamp, 2009.). Komparativne prednosti počele su se promatrati kroz prizmu transportnih troškova, veličine i blizine tržišta i mobilnih proizvodnih faktora. Koncept nove ekonomske geografije predstavlja spoj neoklasične teorije i teorije polarizacije rasta (Fujita i Thisse, 2009.). Ova teorija, prema nekim autorima, produžetak je endogene teorije rasta jer zadržava pretpostavku monopolističke konkurencije, rastuće prinose i efekte prelijevanja. Dok neoklasična teorija predviđa kretanje gospodarstva prema ravnoteži, teorija polarizacije ukazuje na koncentraciju ekonomske aktivnosti u polovima rasta koje

[6] Heckscher-Ohlin model ili faktorsko-proporcionalni model u svojoj najjednostavnijoj varijanti pretpostavlja postojanje dva proizvodna faktora, rada i kapitala. Izvor komparativne prednosti je kretanje proizvodnih faktora unutar svake regije. Regija bogatija jednim od dva proizvodna faktora specijalizirati će se u proizvodnji dobara koji zahtjevaju više tog proizvodnog faktora.

udaljavaju sustav od ravnoteže i uslijed čega se stvaraju nejednakosti. (Eckey i Kosfeld, 2004.).

Početak razvoja koncepta Nove ekonomske geografije uobičajeno se veže za objavu Krugmanovog (1991.) članka „*Increasing returns and Economic Geography*“.[7] Prema nekim autorima, Krugmanov članak nije ništa drugo već „staro vino u novoj boci“ (Schmutzler, 1999.), odnosno, njime su ponovno utvrđene činjenice poznate već desetljećima. Krugman (1991.) koristi Marshallove (1920.) eksternalije vezane za prelijevanje znanja proizašle iz geografske koncentracije industrije, Myrdalovu (1957.) kumulativnu uzročnost procesa rasta, polarizacijske modele i brojne druge elemente koji do pojave Nove ekonomske geografije nikad nisu bili uspješno intergrirani u modelsku formulaciju.

Osnovni Krugmanov model (industrijske) jezgre i (poljoprivredne) periferije na proces kumulativne uzročnosti vezuje Dixit-Stiglitzov (1977.) model monopolističke konkurencije u kojem važno mjesto zauzimaju preferencije potrošača i Samuelson-ov (1954.) model ledenjaka (eng. *iceberg*) prema kojem transportni troškovi „otapaju“ dio proizvoda na putu do potrošača sa geografskom udaljenošću. Glavne implikacije modela su pojava učinka „veličine tržišta“ (eng. *home market effect*) iz kojeg proizlazi da se industrije lociraju u blizini velikih tržišta uslijed čega se smanjuju transportni troškovi i što u konačnici dovodi do aglomeriranja ekonomske aktivnosti. Učinak veličine tržišta iz perspektive gospodarske strukture implicira određeni stupanj specijalizacije, tako će regije s većim brojem stanovništva biti neto izvoznici industrijskih proizvoda, dok će manje regije biti neto izvoznici poljoprivrednih dobara (p. 113, Fujita i Thisse, 2009.).

Razmještaj ekonomskih aktivnosti u prostoru, prema modelu Krugmana (1991.), rezultat je odnosa sila koje potiču aglomeraciju, odnosno grupiranje ekonomskih aktivnosti na određenom prostoru tzv. centripetalnih sila (efekt veličine tržišta, razvijena tržišta rada, pozitivne ekternalije) i sila koje djeluju u suprotnom smjeru, raspršujući ekonomsku aktivnost u prostoru, tzv. centrifugalnih sila (imobilnost proizvodnih faktora, zemljišne rente, negativne eksternalije). Rezultat djelovanja ovih sila, reflektirati će se na regionalne nejednakosti. U slučaju jačeg djelovanja centripetalnih sila doći će do divergencije, odnosno, u slučaju prevage centrifugalnih sila dolazi do divergencije. Važno je napomenuti kako model predviđa

[7] U narednom periodu osnovni model nadogradili su Krugman, Fujita, Vanables, Ottaviano, Walz, Thisse i brojni drugi autori.

više potencijalnih ravnotežnih stanja ovisno o veličini ulaznih parametara (Fujita i Thisse, 2009.).

Osim učinaka u pojedinom poduzeću, proces ekonomije obujma stvara (eksterne) eksternalije na način da privlači nove industrije proizvodnjom konkurentnih intermedijarnih proizvoda. Na ovaj način tržište raste kroz ponudu. S druge strane, kroz rast industrije dolazi do priljeva kvalificiranih radnika koji svojom potražnjom dodatno ubrzavaju kumulativni proces rasta tržišta. Ovaj proces zove se stvaranje tržišta kroz potražnju. Krugman (1991.) ovaj odnos prepoznaje kao učinak „rastuće grude snijega“ (eng. *snowball effect*) koji raste usporedno sa snižavanjem transportnih troškova. Međutim, proces nije beskonačan, obzirom da imigracijski pritisak djeluje na sniženje nadnica, a s druge strane velik broj poduzeća kroz konkurenciju snižava cijene i profite i odbija nova poduzeća za ulazak na takva tržišta (eng. *market crowding effect*), moguće je predvidjeti prostornu disperziju poduzeća i radnika. Ovaj učinak se naziva „otapanje grude snijega“ (eng. *meltdown effect*), a rezultat njegovog djelovanja je usporavanje ekonomske aktivnosti (Fujita i Thisse, 2009.).

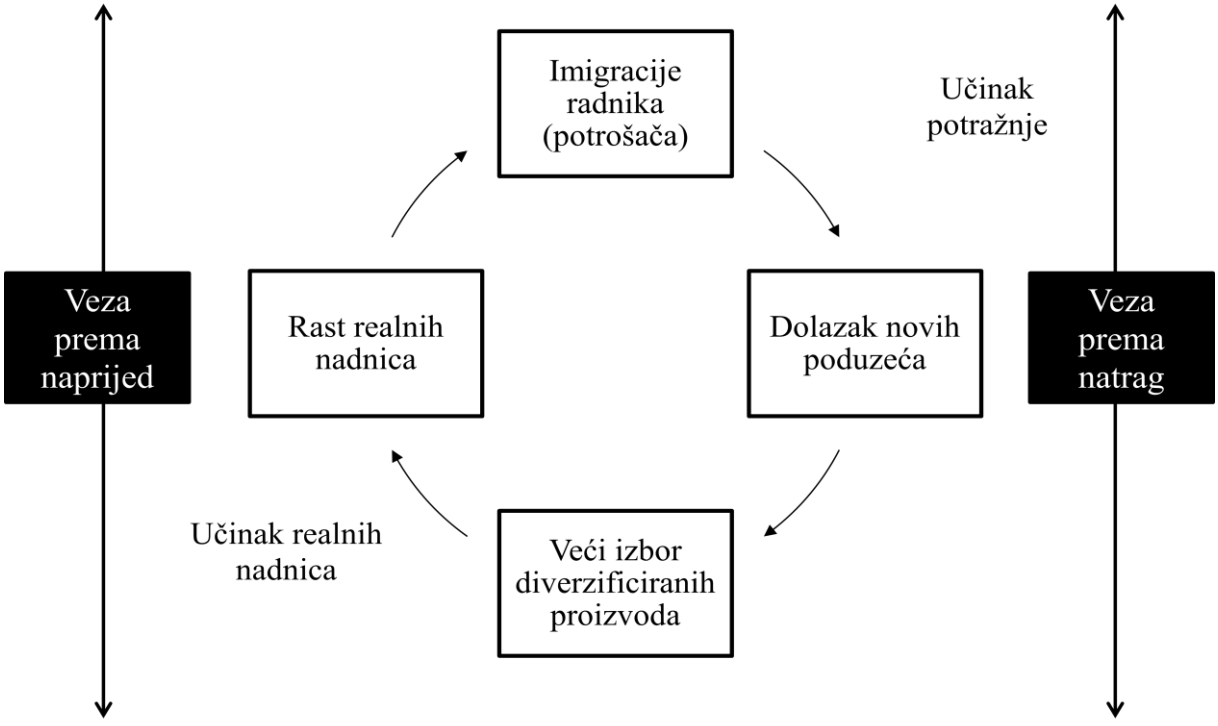


**Grafički prikaz 4: Kumulativna uzročnost kroz veze prema naprijed i natrag**

Izvor: Prikaz autora prema Eckey i Reinhold (2004.)

Kritike modela nove ekonomske geografije uglavnom se odnose na nerealne pretpostavke preuzete iz Dixit-Stiglitzovog modela monopolističke konkurencije. Neki autori ukazuju kako transportni troškovi nisu toliko visoki da bi utjecali na odluke poduzeća o lociranju proizvodnje. Migracija radne snage također je sporna pretpostavka pošto ekonomije nemaju istu razinu mobilnosti radne snage[8] (Ottaviano i Puga, 1998.). Nadalje, Martin (1999.) navodi kako je pretjerana matematička formalizacija teorije dovela do zanemarivanja nekih prostornih čimbenika koji utječu na ekonomski rezultat.

Zaključno, koncept Nove ekonomske geografije kombiniranjem tranportnih troškova, monopolističke konkurencije i ekonomije obujma sa bihevioralnim čimbenicima na strani i poduzeća i radnika objasnio je nejednaku distribuciju ekonomske aktivnosti u prostoru. Unatoč brojnim ograničenjima, ovaj koncept doživio je izuzetnu popularnost među strukom jer je donekle otklonio nedostatke prethodnih teorijskih okvira i time stvorio temelje za novi način promišljanja nedjeljive simbioze prostora i ekonomije.

[8] Poznato je kako je migracija radne snage dosta učestala pojava u SAD, dok primjerice u zemljama/regijama EU pojava nije dovoljno izražena da bi se njenom prisutnošću objasnio proces aglomeriranja ekonomske aktivnosti na određenom prostoru.

# 3. EMPIRIJSKA ISTRAŽIVANJA KONVERGENCIJE

Unutar teorije rasta hipoteza konvergencije jedan je od najčešće istraživanih fenomena. Pitanje konvergencije u suštini je empirijsko, stoga je ekonomska literatura iznjedrila dva pristupa za testiranje prisutnosti konvergencije: regresijski pristup i pristup distribucijske dinamike.

## 3.1 Regresijski pristup

Regresijski pristup ima teorijsko uporište u neoklasičnoj doktrini. Ovaj pristup razvijen je kako bi se na stvarnim podatcima ispitalo da li, i kojom dinamikom, regije konvergiraju kao što je predviđeno neoklasičnim teorijskim okvirom. Empirijsko testiranje konvergencije unutar ovog okvira svodi se na ispitivanje prisutnosti $\beta$ konvergencije, odnosno negativne veze početne razine proizvodnje i stope rasta gospodarstva.

Regresijski pristup uključuje prostornu regresiju (eng. *cross-sectional data*), panel regresiju (eng. *panel data*), i analizu vremenskih serija (eng. *time-series data*).

Alternativni pristup razvijen da se prevladaju neke manjkavosti prethodnog naziva se pristup distribucijske dinamike (eng. *distribution dynamics approach*) i naslanja se na Markov lanac (eng. *Markov chains*) i stohastičke jezgre (eng. *stohastic karnels*).

### 3.1.1 Prostorna regresija

U svojem radu Baumol (1986.) pomoću jednostavne regresije testira konvergenciju predviđenu neoklasičnim okvirom:

(3.1.) $log\left[y_{(t)}/y_{(0)}\right] = a + b\ log\ y_{(0)}$

Lijeva strana jednadžbe (3.1.) predstavlja stopu rasta gospodarstva, a konvergencija se pojavljuje ako koeficijent $b$ ima negativnu vrijednost. Prema ovoj jednadžbi gospodarstva s inicijalno niskom razinom BDP *per capita* rastu po višim stopama.

Kod ovakvog pristupa prisutan je problem pretpostavke zajedničkog ravnotežnog stanja, apsolutne, odnosno bezuvjetne, kovergencije. Kako je i ranije izneseno, nije realno očekivati da zemlje s različitim razinama tehnologije, sklonosti štednji i dr. konvergiraju prema zajedničkom stanju ravnoteže.

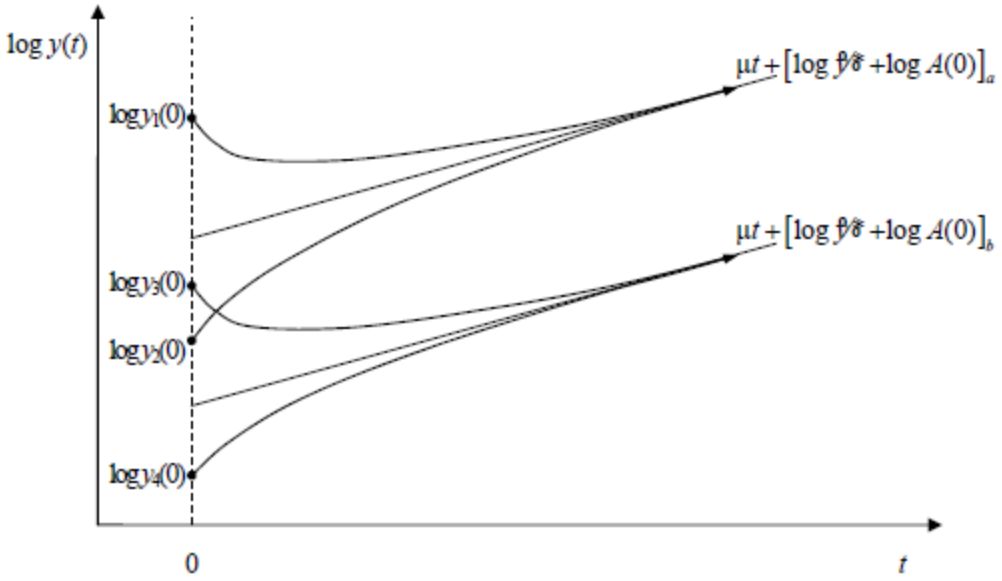


**Grafički prikaz 5: Moguća ravnotežna stanja u neoklasičnom modelu**

Izvor: Magrini (2003.)

Na tom tragu, Barro i Sala-i-Martin (1992.) proširili su regresiju tako da izraz poprima oblik:

(3.2.)

$$(1/t)log[y(t)/y(0)] = \mu + \left(1 - e^{-\beta t}\right)/t \,?\, [log\ \tilde{y}^* + log\ A(0)] - \left(1 - e^{-\beta t}\right)/t \,?\, log\ y(0)$$

Prema tome, prosječna stopa rasta *per capita* dohotka ovisi o inicijalnoj razini *per capita* dohotka, uvjetovanom ravnotežnom razinom *per capita* dohotka po efektivnoj jedinici rada, inicijalnoj razini tehnologije i (egzogenoj) stopi rasta tehnologije. Obzirom da su vrijednosti ovih varijabli nepoznate predložili su slijedeći oblik za testiranje konvergencije:

(3.3.) $(1/t)log[y(t)/y(0)] = c - \left(1 - e^{-\beta t}\right)/t \,?\, log\ y(0) + u(t)$

Ključni parametar predstavljene jednadžbe je $\beta$ koji označava brzinu kretanja gospodarstva prema ravnotežnom stanju, a μ predstavlja slučajnu pogrešku (eng. *error terms*). Jedinstvena slučajna pogreška može se primijeniti samo u slučaju homogene skupine promatranih ekonomskih jedinica karakteriziranih sličnom razinom tehnologije i institucionalnim okruženjem koji bi implicirali zajedničko postojano stanje, u protivnom potrebno je dekomponirati je na dvije komponente, nezavisnu pogrešku (eng. *independent disturbance*) $v(t)$ i agregatni poremećaj (eng. *aggregate disturbance*) $s(t)$ te izmjeriti utjecaj $\varphi$ agregatnog poremećaja na stopu rasta gospodarstva:

(3.4.) $(1/t)log[y(t)/y(0)] = c - \left(1 - e^{-\beta t}\right)/t \; ? \; log\, y(0) + \varphi\, s(t) + v(t)$

Kada se ekonomije razlikuju u nekim parametrima, što implicira više ravnotežnih stanja kojima teže, u izraz (3.4.) potrebno je uvrstiti dodatne objasnidbene varijable za različita stanja ravnoteže.[9] Ova situacija naziva se uvjetnom konvergencijom. Stanja ravnoteže okarakterizirana su rastom dohodaka, postrošnje i odnosa kapitala i rada po (egzogenoj) stopi tehnološkog napretka, dok su varijable po jedinici rada konstantne (p. 4., Magrini, 2003.).

Unutar okvira prostorne regresije analizi konvergencijskog procesa nerijetko se pristupa i pomoću tzv. „half-life" parametra koji se izvodi iz procijenjenog parametra β, a tumači se kao vrijeme potrebno određenom gospodarstvu da prepolovi jaz između inicijalne i ravnotežne razine outputa:

(3.4.') $half - life \equiv log2/\beta$

Na osnovu opisane metodologije nastao je znatan broj radova koji empirijski testiraju postojanje konvergencije na nacionalnoj i regionalnoj razini. Primjerice, Sala-i-Marin (1996) i Barro i Sala-i-Martin (1991., 1992. i 1995.) pronašli su apsolutnu konvergenciju među američkim državama, japanskim prefekturama i nekoliko zemalja Europske unije (Njemačka, Velika Britanija, Francuska, Italija i Španjolska, kao i uvjetnu konverenciju među europskim regijama. Brojni autori nalaze uvjetnu i bezuvjetnu konvergenciju u grupama regija diljem svijeta (Mankiw et al., 1992.; Columbe i Lee, 1993.; Shioji, 1996. i dr.).

[9] Za detaljan prikaz empirijske literature sa različitim objasnidbenim varijablama pogledati Durlauf i Quah (1999.)

Promatrajući istraživanja koja se bave europskim regijama nalazi se prisutnost uvjetne konvergencije (Fagerberg i Verspagen, 1996., Martin, 2001. i dr.). Rezultati variraju ovisno o obuhvatu promatranih zemalja, periodu i primijenjenoj NUTS razini. Na razini država u Europskoj uniji u većini slučajeva potvrđuje se postojanje kovergencije (Austrija: Hofer i Wörgoötter, 1997; Zapadna Njemačka: Niebuhr 2001, Španjolska: de la Fuente, 1996. itd.) iako stope konvergencije variraju među zemljama. Ukupno gledajući, rezultati procjene konvergencije u Europi nešto su manje robusni nego u ostalim djelovima svijeta (Magrini, 2003.)

Većina istraživanja bazirana na ovoj vrsti metodologije rezultirala je stabilnim stopama od približno 2% godišnje. Quah (1996.) ukazuje na moguću pojavu pristranosti kod malih uzoraka uslijed povezanosti prostornih jedinica (eng. *unit roots*) i zaključuje kako konstantne procjene od oko 2% konvergencije mogu biti posljedica „statističke iluzije“ proizašle iz slučajnog hoda (eng. *random walk*), odnosno stohastičnog trenda koji je često obilježje takvih uzoraka. Korištenje metodologije prostorne regresije ima neka dodatna ograničenja. Prvo, može se pojaviti negativna korelacija za zemlje koje se udaljavaju zbog prisutnosti opadajućih prinosa na kapital. Drugo, prostorna regresija testira pristutnost, odnosno odsutnost kovergencije za određene skupine zanemarujući moguća rješenja u spektru između te dvije krajnosti kao i dinamiku koja se zbiva u pozadini razvojnih procesa (Bernard i Durlauf, 1995.). Prema nekim autorima, prostorna regresija ne samo da ne pruža dovoljno informacija, već u određenim situacijama može dovesti i do pogrešnih zaključaka (Magrini, 2003.).

### 3.1.2 Panel regresija

Panel regresija koristi se kako bi se nadvladali određeni nedostatci prostorne regresije. Ograničenim brojem opažanja manja je mogućnost identifikacije generatora rasta. Navedeni nedostatak može se otkloniti promatranjem uzorka tijekom određenog vremenskog perioda (Parker, 2002.). Takav pristup naziva se panel regresija. Metodologijom panel regresije se uvažavaju se ne samo prostorni, već i dinamički čimbenici razvojnog procesa.

U usporedbi s prostornom regresijom u kojoj se stope rasta i vrijednosti nezavisnih varijabli uprosječe i tako zanemare promjene tijekom vremena i određena odstupanja, kao i neke

specifične karakteristike promatranih jedinica, u regresijskom panel pristupu takve se pojave mogu opisati u obliku posebnih opažanja (*dummy* varijabli) i na taj način ocjeniti njihovi učinci. Zbog zanemarivanja određenih specifičnosti promatranih jedinica pristup prostorne regresije može rezultirati pristranim procjeniteljima što se u regresijskom panel pristupu eliminira korištenjem panel regresije sa fiksnim efektom kojim se kontrolira neopažena heterogenost u OLS (eng. *ordinary least squares*) i dvo-stepenoj SLS regresiji (eng. *two-stage least squares regresion*) (Borys et al. 2008.).

U najjednostavnijem obliku panel regresija sa fiksnim efektom (eng. *fixed effect panel data*) za testiranje prisutnosti konvergencije ima sljedeći oblik:

(3.5.) $log[y(t)/y(t-1)] = c_0 + c_1(t) - b\ log\ y(t-1) + u(t)$

Pri čemu je konstanta $c$ dekomponirana na nemjerljiv specifični učinak promatrane jedinice $c_0$ i vremensko specifičan učinak $c_1$ koji utječe jednako na sve promatrane jednice. Inicijalno je za procjenu korišten procjenitelj metodom najmanjih kvadrata za dummy varijable. Kasnije je uveden 2-stepeni GMM procjenitelj (eng. *2-step GMM estimator*). GMM i sistemskim procjeniteljem diferencira se regresijska jednadžba kako bi se izbjegla pristranost koja proizlazi iz neopaženih efekata specifičnih za pojedinu promatranu jedinicu.

Rezultati istraživanja primjenom panel regresije nerijetko su u suprotnosti s rezultatima dobivenim korištenjem prostorne regresije. Lall i Yilmaz (2001.) ne nalaze prisutnost apsolutne konvergencije među američkim državama kao Barro i Sala-i-Martin. De la Fuente (2000) nalazi konvergenciju za regije pet najvećih europskih zemalja između 26% i 39%, ovisno o primjenjenoj metodologiji. Nešto niže stope su zapažene kod regija pojedinačnih zemalja: Njemačka 10% (Funke i Strulick, 1999.), Španjolska 12,7% (de la Fuente, 1996.). Ukupno gledano, rezultati procjene konvergencije korištenjem panel regresije s fiksnim efektom uobičajeno su viši od 2% koji proizađu iz prostorne regresije. Kod korištenja vremenskih serija može se pojaviti pristranost GMM procjenitelja, zbog čega je potrebno primijeniti sistemski GMM procjenitelj, sistem koji kombinira jednadžbu s prvim diferencijama s jednadžbama u kojima su instrumenti vremenski pomaknute diferencijacije (Magrini, 2003.).

De la Fuente (2000.) navodi kako je razlog tolikih odstupanja rezultata prostorne i panel regresije u tome što procjene panel regresija umjesto dugoročnih dinamika rasta obuhvate kratkoročne prilagodbe oko trenda i vrlo malo govore o brzini kojom se gospodarstva približavaju svojim ravnotežnim stanjima. S jedne strane, očita je prednost uporabe panel regresije u odnosu na prostornu jer se mogu kontrolirati problemi endogenosti i nemjerljive heterogenosti, međutim, upravljanje heterogenošću rezultira neotkrivenim obrascima ponašanja različito razvijenih jedinica u skupu (Magrini, 2003.). Panel regresija, dakle, s metodološke strane predstavlja napredak, ali suštinski ne može uspješno odgovoriti na određena pitanja.

### 3.1.3 Analiza vremenskih serija

Treći način izučavanja konvergencije unutar regresijskog okvira je primjena analize vremenskih serija. Kod ovog pristupa konvergencija se bazira na poimanju povezanosti prostornih jedinica (eng. *unit roots*) i kointegraciji.

Metoda je na osnovu panel pristupa razvijena od strane Evansa i Karrasa (1996.a i 1996.b) pri čemu se prisutnost konvergencije za gospodarstva $1, 2, \dots N$ utvrđuje ukoliko, ovisno raspoloživim informacijama, očekivana odstupanja $y_{1,t+k}, y_{1,t+k}, \dots, y_{N,t+k}$, od prosječne vrijednosti svih gospodarstava $\bar{y}_t$ kreću prema konstantnoj vrijednosti kako $k$ teži ka beskonačnosti:

(3.6.) $lim_{k*x} E\left(y_{i,t+k} - \bar{y}_{t+k} \middle| I_t\right) = \mu_i$

Ako, i samo ako, svaki $y_{i,t} - \bar{y}_t$ ispunjava uvjet stacionarnosti, dok je svaki $y_{i,t}$ nestacionaran. Konvergencija je apsolutna ako za svaki $i$ vrijedi $\mu_i = 0$, odnosno, konvergencija je uvjetna ako za svaki $i$ vrijedi $\mu_i \neq 0$. Prisutnost divergencije utvrđuje se ako $y_{i,t} - \bar{y}_t$ za svaki $i$ nije stacionaran.

Korištenjem izraza (3.4.) uz pretpostavku raspoloživosti prostornih podataka za dodatne varijable koje predstavljaju proxy varijable za različita postojana stanja, proizlazi:

(3.7.) $\Delta y_{i,t} = d_i - \eta_i\left(y_{c,t-1} - \tau_{t-1}\right) + \xi_{i,t}$

Pri čemu je $d$ parametar koji inkorporira proxy varijable za različita ravnotežna stanja, dok $\eta$ predstavlja zajednički trend postojanog stanja razine *per capita* dohodaka, a $\xi$ stacionarnu slučajnu pogrešku sa konačnom varijancom i prosjekom 0.

Kosristeći prethodni izraz i oduzimanjem prosjeka parametara od njihovih vrijednosti dobije se:

(3.8.) $\Delta(y_{i,t} - \bar{y}_t) = (d_i - \bar{d}_t) - \eta(y_{c,t-1} - \bar{y}_{t-1}) + (\xi_{i,t} - \bar{\xi}_t)$

Koji može imati problem korelacije slučajnih grešaka za $\xi_{i,t} - \bar{\xi}_{i,t}$, stoga se analizi konvergencije pristupa korištenjem proširene Dickey-Fullerove regresije (ADF):

(3.9.) $\Delta(y_{i,t} - \bar{y}_t) = \delta_i + \rho_i(y_{c,t-1} - \bar{y}_{t-1}) + \square_{r-1}^{q} \phi_{ir} \Delta(y_{c,t-1} - \bar{y}_{t-1}) + \upsilon_{it}$

Pri čemu su $\phi_{i,1}, \phi_{i,2}, \dots, \phi_{i,p}$ parametri proizašli iz serijske korelacije $\upsilon_{it}$ je nekorelirana slučajna greška serije s konačnom varijantom i sredinom 0. Parametar $\rho_i \geq 0$ ukazuje na odsutnost konvergencije, dok je konvergencija prisutna ukoliko je $\rho_i$ negativan.

Bernard i Durlauf (1995.) razvili su nešto drugačiji pristup.[10] Njihov pristup konvergenciji ne razmatra svojstvo relacije između inicijalnog dohotka i rasta tijekom određenog perioda, već odnos dugoročne prognoze *per capita* dohotka obzirom na inicijalne uvjete.

Prema metodi spomenutih autora, baziranoj na modelu vremenskih serija, konvergencija se može definirati kao proces održavanja jednakosti očekivanih dugoročnih *per capita* dohodaka među promatranim jedinicama, odnosno:

(3.10.) $\lim_{k \star x} E\left(y_{i,t+k} - y_{j,t+k} \middle| I_t\right) = 0$

Dakle, ekonomije $(i, j)$, pri danoj razini informacija $(I_t)$, konvergiraju u vremenu $t$ ako prognoza razlike njihovih outputa teži 0. Izraz (3.10) primjenjuje se kada se želi ispitati prisutnost procesa konvergencije između dvije promatrane ekonomije. Ukoliko se prisutnost procesa želi ispitati simultano za grupu prostornih jedinica $p = 1, \dots, N$ koristi se:

[10] Primjena metodologije vremenskih serija u testiranju konvergencije povezuje se i s ranijim radovima: Durlauf (1989.) i Quah (1992.)

(3.11.) $\lim_{k\star x} E\left(y_{1,t+k} - y_{p,t+k}\middle|I_t\right) = 0 \qquad \forall\, p \;?\; 1$

Zahvaljujući ovakvim postavkama modela, prognoze konvergencije u vremenskim serijama ne moraju imati obilježje „sve ili ništa“, već je moguće utvrditi da proces konvergencije nije prisutan u čitavoj promatranoj grupi ekonomija, ali među nekim jedinicama jest (Durlauf, Quah, 1999.).

Karakteristika dinamičke definicije konvergencije u vremenskim serijama uključuje pojavu β konvergencije, odnosno procesa smanjenje razlika između outputa promatranih ekonomija:

(3.12.) $\lim_{k\star x} E\left(y_{i,t+T} - y_{j,t+T}\middle|I_t\right) < y_{i,t} - y_{j,t}$ ako je $y_{i,t} > y_{j,t}$

Bitno je uočiti distinkiciju između prognoze konvergencije u vremenskim serijama i β konvergencije obzirom da očekivano smanjenje razlika (β konvergencija) ne implicira nužno njihovo eventualno nestajanje (Durlauf, Quah, 1999.).

Primjenom ADF metodologije Evans i Karras (1996.a) pronalaze prisutnost uvjetnog konvergencijskog procesa u periodu 1929-1991. za 48 američkih država. Sličnu metodologiju za pokrajine zapadne Njemačke primjenili su Funke i Strulik (1999.) te izvjestili o postojanju uvjetne konvergencije među u razdoblju između 1970. i 1994. godine.

Istraživanja Carlino i Millsa (1993., 1996.a i 1996.b) nisu potvrdila postojanje konvergencijskog procesa u SAD-u, međutim, uvođenjem posebnih prilagodbi radi pojave određenih šokova prikazali su prisutnost konvergencije za dio regija i država. Daljnja istraživanja Loewy i Papella (1996.) potvrdila su prisutnost procesa uvjetne konvergencije na području SAD-a. Također, rad Tomljanovich i Vogelsanga (2001.) navodi na isti zaključak.

Koristeći metodologiju razvijenu u radu Bernard i Durlaufa (1995.) za regije SAD tijekom perioda od 1929. do 1997. godine, Tsioinas (2001.) izvještava o nepostojanju uvjetne konvergencije što je u očitoj suprotnosti s gore navedenim rezultatima istraživanja.

Razlog odstupanjima u rezultatima na prilično sličnim uzorcima proizlazi iz razlike u definicijama konvergencije, pri čemu potonje opisana metodologija pribjegava nešto strožim uvjetima za utvrđivanje konvergencije (Bernard i Durlauf, 1995.). Primjena metodologije analize vremenskih serija u istraživanju konvergencije, nije toliko učestala, kako zbog očitog nedostatka

dovoljno dugih vremenskih serija, poglavito na regionalnoj razini, tako i zbog očitog nesuglasja rezultata s onima proizašlim primjenom panel analize ili prostorne regresije (p. 6. Magrini, 2007.).

Pristup regresijske analize, ukupno gledano, ima svoja određena ograničenja. Možda najvažniji nedostatak regeresijskog pristupa, proizlazi iz njegove ograničene informativnosti. Negativni odnos stopa rasta i inicijalnih uvjeta, beta konvergencija, ne implicira nužno smanjenje prostornih dispariteta, sigma konvergencije. Kako je ranije objašnjeno (poglavlje 2.2.) beta konvergencija je nužna, ali ne i dovoljna za sigma konvergenciju. Baro i Sala-i-Martin (1996.) pozivaju da se istraživanje beta konvergencije poprati izučavanjem sigma konvergencije kako bi se izbjeglo donošenje pogrešnih zaključaka, iako ni ovakav pristup nije u stanju uvijek pružiti učinkovito rješenje za obuhvatiti sve intradistribucijske dinamike unutar procesa konvergencije (Quah, 1996.). Osim toga, regresijskim pristupom nerijetko previdi čitav niz dinamičkih procesa unutar prostora, poput formiranja konvergencijskih klubova i sl.

Iako je regresijski pristup proizašao iz tradicionalnog neoklasičnog modela rasta, ukoliko je cilj istraživanja potvrditi njegovu utemeljenost na stvarnim podatcima, čak i kada u tome uspije, može se dogoditi da ostavi prostora za druga potencijalna objašnjenja procesa konvergencije. U najboljem slučaju, rezultati nisu u suprotnosti s neoklasičnim konceptom, ali ne mogu isključiti druge pristupe. Stoga, ukoliko se istraživanjem želi utvrditi jasna distinkcija između različitih koncepata rasta, pristup prostorne regresije nije primjenjiv, iz čega proizlazi da je njegova znanstvena relevantnost upitna (Magrini 2007.).

Zaključno, regresijski pristup empirijskom istraživanju konvergencije potječe od neoklasičnih koncepata rasta, a u tim okvirima impliciraju pretpostavke koje isključuju otvorenost gospodarstva što je, poglavito na subnacionalnoj razini, prilično sporno. Tri različita pristupa nerijetko rezultiraju bitno različitim prognozama stopa konvergencije, ali i rezultatima koji su oprečni. Nadalje, regresijskim pristupom analizi konvergencije određene informacije i dinamike procesa ostanu skrivene pa je takva istraživanja potrebno popratiti s neregresijskim analizama, poput ispitivanja prisutnosti sigma konvergencije. Iz navedenog proizlazi kako regresijski pristup ima određena ograničenja, stoga ne čudi da je nezadovostvo metodološkim pristupom unutar regresijske analize motiviralo istraživače da razviju drugačije pristupe istraživanju konvergencijskih procesa.

## 3.2 Pristup distribucijske dinamike

Alternativni pristup analizi konvergencijskog procesa razvijen je sa ciljem da se prevladaju neka ograničenja koja se mogu pojaviti koristeći regresijski pristup. Jedan od najvećih kritičara regresijkog pristupa, Quah (1993. a, b, 1994., 1996. a, b, 1997.) ponudio je značajan odmak od prethodno opisanog koncepta analizirajući prostornu distribuciju dohodaka po stanovniku koristeći stohastičke karnele.

U najjednostavnim modelu distribucijske dinamike diferencijalnom stohastičkom jednadžbom opisane su promjene distribucije. $F_t$ predstavlja prostornu distribuciju dohotka u vremenu $t$. Svakom $F_t$ pridružuje se mjera vjerojatnosti $\lambda_t$,

(3.13.) $\lambda_t((-\infty, y]) = F_t(y), t \geq 1 \qquad \forall\, y \in R$

(3.14.) $\lambda_t = T^*(\lambda_{t-1}, u_t) = T_u^*(\lambda_{t-1})$

Shema obuhvaćena izrazom (3.14) analogna je autoregresivnom modelu prvog reda iz standardne analize vremenskih serija, pri čemu je $T^*$ oznaka kartezijanskog produkta mjera vjerojatnosti s nizom poremećaja (eng. *sequences of distrurbance*) označenih s $u_t$, dok $T_u^*$ predstavlja definiciju $T^*$ s apsorbiranim nizom poremećaja.

Struktura $T^*$ može otkriti određene intradistribucijske dinamike, a omogućava i njihovu kvantifikaciju, stoga se pomoću $T^*$ može predvidjeti prostorna distribucija dohotka tijekom vremena ($F_t$) s pripadajućom vjerojatnošću ($\lambda_t$,). Dakle, iz spektralne strukture operatora $T^*$ može se pročitati kojom brzinom se odvija dinamika promjena nakon početne distribucije $F_0$ te kvantificirati vjerojatnost pojave konvergencije kao i vrijeme u kojem se očekuje njena eventualna pojava.

Da bi se shvatio $T^*$ kroz funkciju impulsnog odgovora (eng. *impulse response function*) potrebno je poremećaje $u$ postaviti na 0 i diferencijalnu jednadžbu pokrenuti naprijed, što će rezultirati proxy varijablom za $\lambda_t$.

(3.15.) $T^*(\lambda_{t+s-1}, 0) = T^*(T^*(\lambda_{t+s-2}, 0),0)$

$$\vdots$$

$$= T^*(T^*(T^* \dots (T^*(\lambda_t, 0),0) \dots 0),0),$$

Kako $s \to \infty$ iz izraza (3.15) moguće je predvidjeti različite dinamike u distribuciji dohodaka bilo da ekonomije konvergiraju, bilo da se grupiraju u konvergencijske klubove ili se jednostavno razilaze. Ukoliko se $\lambda_{t+s}$ kreće prema jednoj točci (eng. *point mass*) zaključuje se da promatrane ekonomije konvergiraju. S druge strane, bimodalna (eng. *twin-peaked*) distribucija ukazuje na raslojavanje pri čemu bogate postaju bogatije, a siromašne siromašnije. Ova situcija može ukazivati i na grupiranje u konvergencijske klubove pri čemu je prisutan proces sustizanja, međutim, unutar različitih podskupina. Općenito, ukoliko se pojavi bilo koji oblik multimodalne distribucije, odnosno kretanje $\lambda_{t+s}$ prema više točaka, zaključuje se da je prisutna polarizacija promatranih prostornih jedinica.

Opisana metodologija ne samo da pruža veću fleksibilnosti u procjeni konvergencije u tehničkom smislu, njena glavna prednost je u tome što daje globalnu sliku o distribuciji dohodaka u prostoru Quah (1996. c).

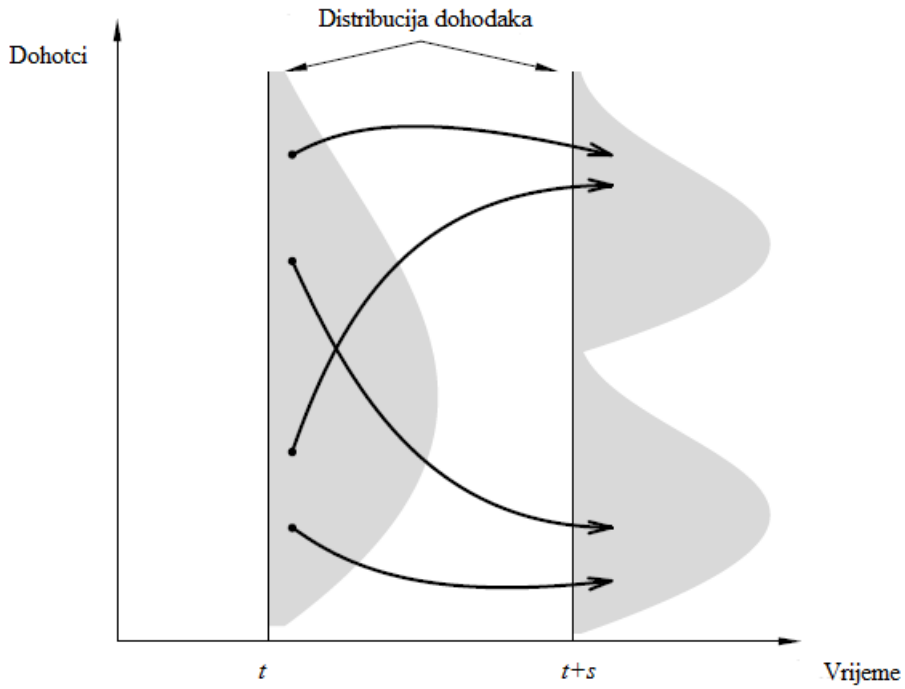


**Grafički prikaz 6: Bimodalna distribucija dohodaka**[11]

Izvor: Prikaz autora prema Quah (1996.c)

Nadalje, svom radu Quah (1993. a) predlaže da se opažanja dohodaka svrastaju u tablicu podjele na pet djelova: prvi dio obuhvaća dohotke po stanovniku na određeni dan koji ne prelaze više od jedne četvrtine prosječnog svjetskog dohotka, drugi dio obuhvaća one koji su veći od četvrtine, a ne prelaze jednu polovinu, treći koji su veći od polovine a ne premašuju prosjek, četvrti veći od prosjeka ali ne više od dvostruko i peti u koji spaadaju svi ostali dohotci.

**Tablica 1: Realni BDP po stanovniku (relativno u odnosu na svjetski prosjek)**

| Broj opažanja | Gornja granica | | | | |
|---|---|---|---|---|---|
| | **1/4** | **1/2** | **1** | **2** | **∞** |
| (456) | .97 | .03 | | | |
| (643) | .05 | .92 | .04 | | |
| (639) | | .04 | .92 | .04 | |
| (468) | | | .04 | .94 | .02 |
| (508) | | | | .01 | .99 |
| | .24 | .18 | .16 | .16 | .27 |

Izvor: Prikaz autora prema Quah (1993. a)

[11] Izvor bimodalne distribucije prema Quahu (1997.a), primjenom kasnije opisane metodologije, može se pronaći u prostornim preljevanjima i obrascima međusobne trgovine promatranih jedinica.

Obzirom da ovakav prikaz omogućava praćenje kretanja ekonomija među različitim ćelijama moguće je formirati tranzicijsku matricu vjerojatnosti $M_t$ u kojoj su svi unosi pozitivni, a suma retka jednaka je 1. Redovi i stupci $M_t$ indeksirani elementima diskretizacije gdje svaki redak predstavlja dio promatranih jedinica koje počinju od tog elementa retka i završavaju u različitim stupcima. U posljednjem retku nalaze se informacije o dinamici kretanja prostorne distribucije dohotka.

Pretpostavljajući vremensku nepromjenjivost tranzicijskog mehanizma model iz izraza (3.14.) postaje vremenski homogen (konačan) Markov lanac. Iteracijom prikazanom izrazom (3.15.) dolazi se do prediktora buduće prostorne distribucije:

(3.16.) $\lambda_{t+1} = M'\lambda_t \qquad \forall\, s \geq 1: \qquad \lambda_{t+s} = (M^s)'\lambda_t$

Matrica $(M^s)'$ sadrži informacije o vjerojatnosti kretanja između dohodovnih skupina tijekom $s$ jedinica vremena zadovoljavajući:

(3.17.) $\lambda_\infty = M'\lambda_\infty$

Vektor $\lambda_\infty$ je vektor ergodičkog retka i odgovara konačnoj vrijednosti relacije (3.16.) kako $s \to \infty$. Drugim riječima, njime se opisuje dugoročna prostorna distribucija dohotka promatranih jedinica.

Za razmatranje konvergencijskog procesa razmatra se ponašanje $\lambda_{t+s}$. Ukoliko se $\lambda_{t+s}$ kreće prema jednoj točci moguće je utvrditi prisutnost konvergencije, alternativno, ukoliko $\lambda_{t+s}$ teži dvjema točkama zaključuje se da je među promatranim prostornim jedinicama prisutan proces divergencije.

Premda Quah (1996. b) tvrdi da se grupiranjem u pet razreda neće pojaviti ozbiljnije distorzije i da će se zadržati glavna obilježja Markovog lanca, Magrini (1999.) predlaže uporabu histograma i optimizaciju granica dohodaka u cilju reduciranja pristranosti disagregiranja i minimiziranja grešaka aproksimacije. Bulli (2001.) ukazuje na mogućnost pogrešnih zaključaka koristeći opisani postupak i sugerira primjenu metode regenerativnog disagregiranja (eng. *regenerative discretisation method*) koja je potekla iz literature o Markovom lancu uz Monte Carlo metodologiju.

Kako bi se u cjelosti izbjegli problemi proizašli iz disagregiranja (Quah, 1996.a i 1997.) predlaže primjenu stohastičkih jezgri (eng. *stohastic karnels*) koji se za potrebe analize konvergencijskog procesa mogu prikazati u obliku trodimenzionalnih grafikona.

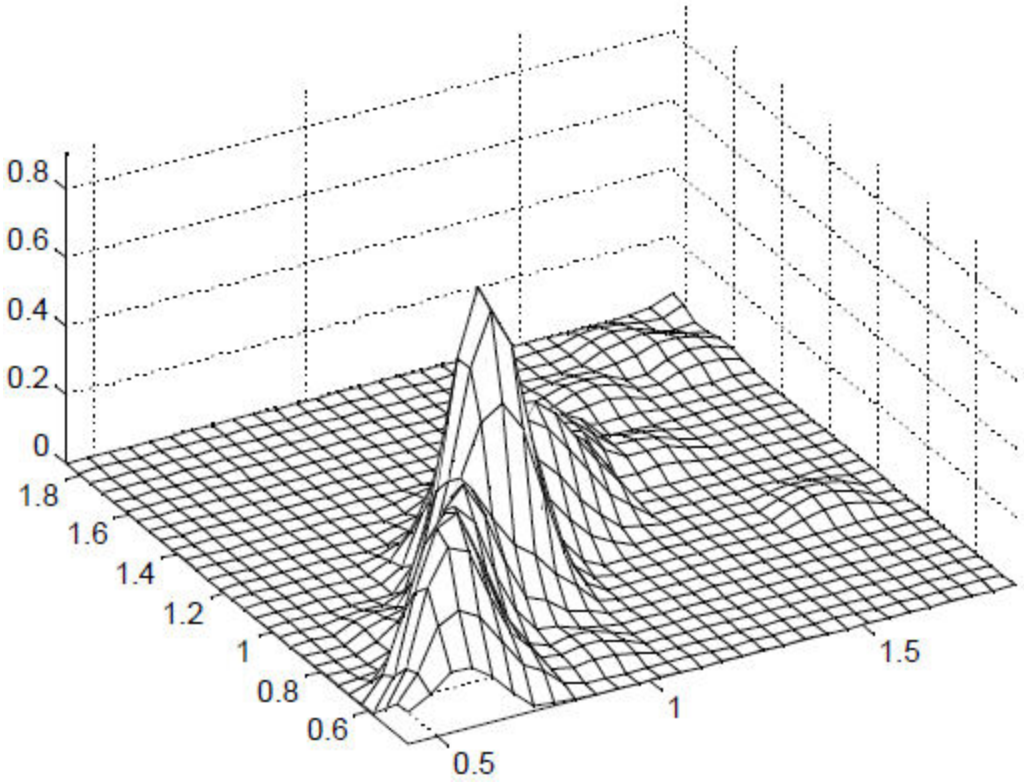


**Grafički prikaz 7: Relativna dinamika dohotka po stanovniku odabranih NUTS regija 1980-1995.**

Izvor: Magrini (2003.)

Grafičkim prikazima 7 i 8 predočena je tranzicijska dinamika dohodaka *per capita* za 110 NUTS regija u odnosu na prosjek EU12 tijekom 15-godišnjeg perioda. Konkretno, s lijeve strane grafičkog prikaza 7 nalaze se opažanja iz 1980. godine, dok desna strana prikaza bilježi opažanja iz 1995. godine (na korespondentnom grafičkom prikazu 8 vertikalna os odnosi se na početnu, a horizontalna os na završnu godinu promatranog razdoblja). Na oba prikaza uočava se grupiranje oko dijagonale na 45 stupnjeva što ukazuje na zadržavanje početnih pozicija, odnosno nepostojanje konvergencijskog procesa. U protivnom, kada bi konvergencijski proces bio prisutan, prikaz bi bio rotiran za 90 stupnjeva u smjeru kazaljke na satu, pri čemu bi se vrijednosti opažanja grupirale oko vrijednosti 1 na desnoj osi, paralelno s lijevom.

Temporalna homogenost Markovog lanca potvrđena je radom Johnsona (2000.) koji primjenom opisane metodologije za dohotke američkih država nalazi dokaze o prisutnosti konvergencijskog procesa.

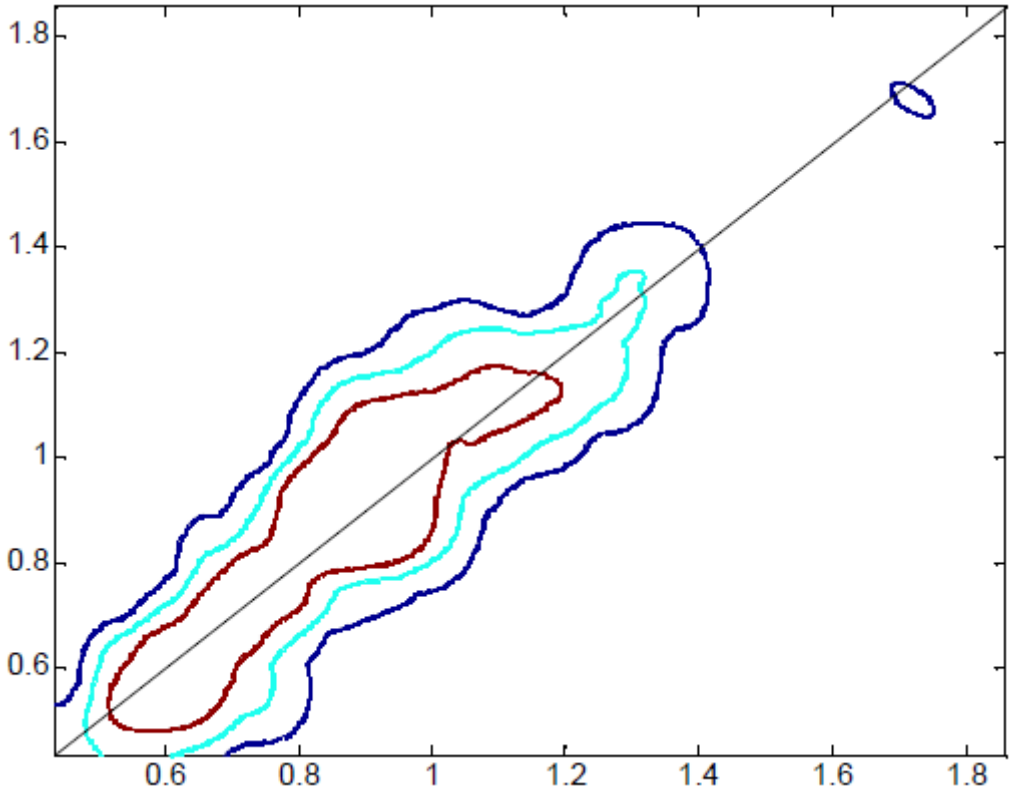


**Grafički prikaz 8: Relativna dinamika dohotka po stanovniku odabranih NUTS regija 1980-1995.** [12]

Izvor: Magrini (2003.)

Opisana metodologija formalizira određene činjenice o dinamici prostorne distribuciji, međutim, još uvijek ne objašnjava obrazace njihovog ponašanja. Da bi se dobilo više informacija ne samo o intradistribucijskoj dinamici, već i o međusobnim interakcijama prostornih jedinica i ponašanju čitave skupine, metodologiju je potrebno dodatno prilagoditi. Kako metodologija stohastičkih jezgri omogućava povezivanje distribucija Quah (1997. b) predlaže primjenu kondicionalne verzije distribucijskog pristupa.

[12] Prikaz korespondira grafičkom prikazu 7, ali odnosi se na pogled odozgo koristeći konture na određenim razinama koje se potom projeciraju na dvodimenzionalni grafikon.

Uz pretpostavku egzogenosti kondicionalnih varijabli, jednostavna kondicionalna shema $\Psi$ za svaku $i$ ekonomiju unutar zadane grupe $S$ u vremenu $t$ razmatra:

(i) cjelobrojni vremenski pomak $\tau_i(t)$

(ii) podskupine $C_i(t)$ od $S$

(iii) set ponderiranih vjerojatnosti $w_i(t)$ od $S$ nikad pozitivan izvan $C_i(t)$

Unutar predstavljene sheme, $C_i(t)$ označava skupinu funkcionalno povezanih ekonomija s obzirom na teorijske postavke i utjecajima na ekonomiju $i$. Ponderirane vjerojatnosti $w_i(t)$ opisuju relativnu snagu utjecaja pojedine ekonomije unutar podskupina na evoluciju $i$, dok $\tau_i(t)$ predstavlja vremenski odmak potreban da se na ekonomiju $i$ prenesu utjecaji promjena koji se odvijaju u pripadajućoj podskupini $C_i(t)$. Ukoliko su inicijalna opažanja dohodaka *per capita* predstavljena s $Y = \{Y_i(t): i \in S \text{ i } t \geq 0\}$, kondicionalna verzija $Y \mid \Psi = \tilde{Y}$definira se kako slijedi:

(3.18) $\tilde{Y}_i(t) \,..\, Y_i(t)/\hat{Y}_i(t)$

Pri čemu za svaki $j \in C_i(t)$ vrijedi:

(3.19) $Y_i(t)$ ... $\square_j w_j(t) Y_i[t - \tau_i(t)]$

Odnosno, opažanja u kondicionalnoj verziji $Y \mid \Psi = \tilde{Y}$ ostvarene su normaliziranjem opažanja za svaku ekonomiju s vaganim prosjekom dohodaka po stanovniku unutar funkcionalno povezanih regija.

Nakon definiranja kondicionalne sheme može se vidjeti kako set utjecaja djeluje na prostornu distribuciju dohodaka. Primjerice, ukoliko metoda jezgri mapirana grafički rezultira prikazom na kojem su opažanja koncentrirana oko jedinične vrijednosti osi koja odgovara uvjetnim vrijednostima i paralelna su s osi na kojem se nalaze bezuvjetne vrijednosti zaključuje se da su prisutna dva konvergencijska kluba, odnosno bimodalna distribucija. Nadalje, zaključuje se da definirani set utjecaja zapravo determinira bimodalnost. Također, analizom procjenjenih stohastičkih jezgri u vremenu $t$ u odnosu na odgovarajuću distribuciju u vremenu $t + \tau$ moguće je dobiti informacije o dinamikama.

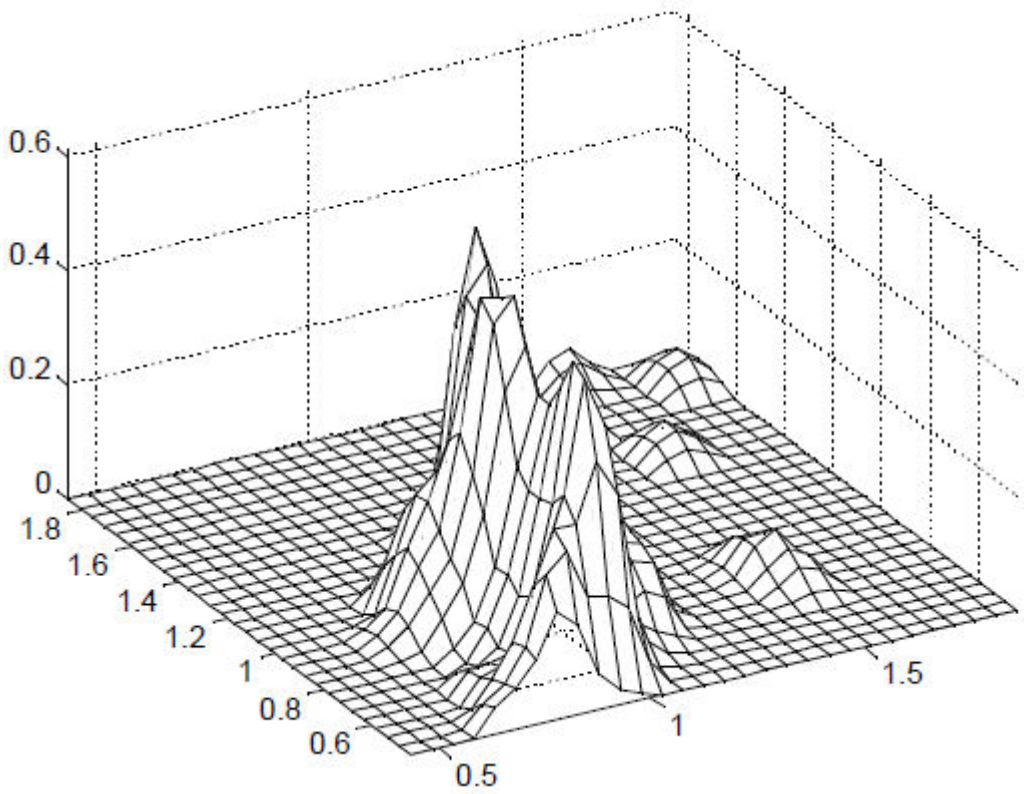


**Grafički prikaz 9: Prostorno uvjetovana relativna dinamika dohotka po stanovniku odabranih NUTS regija, 1980.**

Izvor: Magrini, 2003.

Primjenom opisane metodologije Quah (1997.a) zaključuje kako su rast i konvergencija pod utjecajem prostornih prelijevanja i trgovinske dinamike. U drugom istraživanju Quah (1996.a) NUTS regija tijekom 1980-ih nalazi da važan utjecaj na distribucijsku dinamiku imaju nacionalni makro čimbenici i, posebno, prostorni učinci prelijevanja.

Iako ne često, prilikom primjene metodologije distribucijske dinamike moguća je pojava problema razlikovanja relevantnosti karakteristika podataka u odnosu na prirodnu varijabilnost istih. Za navedeno ograničenje ne postoji jedinstveno rješenje, međutim, adekvatnim vrednovanjem prostornih učinaka moguće je izbjeći pogrešne zaključke (Magrini, 2003.).

Zaključno, distribucijski pristup analizi konvergencije predstavlja radikalan zaokret u odnosu na regresijski pristup, kao i solidnu alternativu pogotovo kada je intencija identificiranje izvora intradistribucijske dinamike. Iako se napredak može ocijeniti znatnim i uspješnim, uvažavajući

određena ograničenja, može se utvrditi da postojeći metodološki okvir ostavlja dovoljno prostora za daljnja unapređenja.

# 4. ZNAČAJ SPECIJALIZACIJE ZA REGIONALNI RAZVOJ

*„The idea that specialization could lead to increasing returns is as old as ceonomics as discipline“* (Roomer, 1987.)

## 4.1 Teorijske odrednice specijalizacije regija

Teorijski koncepti kroz koje je moguće razmotriti učinke specijalizacije na regionalni razvoj, posebice na konvergenciju, datiraju još od kraja 19. stoljeća. Do 1960-ih godina nastao je čitav niz radova baziranih na mikroekonomskom modeliranju koji iz različitih kuteva promatraju aglomeriranje ekonomske aktivnosti u prostoru.

**Tradicionalna lokacijska teorija** (eng. *traditional location theory*) pretpostavlja savršenu konkurenciju i konstantne prinose na obujam stoga je očekivani rezultat trgovina proizvodima različitih industrija, a samim time, očekuje se trgovina među regijama različitih proizvodnih struktura (Capello i Nijkamp, 2009.).

Unutar ovog teorijskog pravca čitav niz radova nastao je s namjerom da se objasne značajke aglomeracijske ekonomije s naglaskom na izvore rasta, ali i njegove posljedice. Brojni radovi nastali su na tragu postavki Marshalla (1920.) koji razmatra eksternalije proizašle iz preljevanja znanja te Hoovera (1948.) koji prednosti iz aglomeracije nalazi u internim ekonomijama obujma koje se pojavljuju radi veličine tržišta i prema kojem „čak i ukoliko izostanu inicijalne diferencijacije, obrasci specijalizacije i koncentracije aktivnosti neizbježno će se pojaviti“. Učinci eksternalija proizašlih iz aglomeracije ekonomske aktivnosti u prostoru razlikuju se međusobno među sektorima (Duranton i Puga, 2000.).

Literatura nastala na postavkama Marshala nalazi tri glavna razloga zbog kojih se industrije lokaliziraju na određenim područjima podupirući rast. Prvo, koncentracija poduzeća nudi tržište radne snage određenih vještina specifičnih za promatranu industriju. Drugo, lokalizirane industrije mogu poduprijeti proizvodnju netrživih (eng. *nontradable*) specijaliziranih inputa. Treće, prelijevanja znanja među umreženim poduzećima unutar iste industrije rezultiraju relativno boljom proizvodnom funkcijom u odnosu na samostalne proizvođače (Krugman, 1991.).

Među ekonomistima, međutim, postoji debata o tome kakva struktura gospodarstva pogoduje prelijevanjima znanja. Prema nekim autorima, primjerice Loeschu (1954.), eksternalije se pojavljuju samo među poduzećima unutar iste industrije. S druge strane, dio autora smatra kako restrikcija eksternalija na određenu industriju ignorira važan izvor interindustrijskog preljevanja znanja (Feldman i Audretsch, 1999.). Jacobs (1969.) primjerice smatra da diverzificirana struktura pogoduje rastu i kako različitost industrija ide u prilog eksternalima, uz prisutnost zajedničke baze koja potiče interakcije među industrijama.

Ključna značajka ove skupine teorijskih koncepata jest neposrednost (eng. *proximity*) koja ne samo da omogućava omogućava snižavanje transportnih troškova i tako povećanje produktivnosti, već i potiče nastanak klastera za koje se smatra da imaju pozitivne učinke na ekonomsku aktivnost.

Zaključno, tradicionalna lokacijska teorija ističe važnost agregatne ponude i potražnje regija te ulogu ekonomije obujma i aglomeracije. Osim toga, čimbenici poput stope štednje, tehnološkog napretka i rasta populacije determiniraju regionalni rast (Hulten, Schwab, 1993.). Dispariteti u prostornoj distribuciji ekonomskih aktivnosti rezultat su učinaka aglomeracijske ekonomije i eksternalija (Dawkins, 2003) stoga se unutar ovog teorijskog pristupa uslijed djelovanja različitih čimbenika očekuje produbljavanje razlika među regijama, a ne konvergencija.

Alternativni pristup objašnjenju aglomeraciji ekonomske aktivnosti, pa i specijalizaciji, razvijao se unutar **teorija međunarodne trgovine** (eng. *international trade theory*). U tradicionalnoj trgovinskoj teoriji, tijek dobara među zemljama determiniran je komparativnom prednošću. Komparativna prednost „Ricardovog“ tipa ostvaruje se zbog razlika u produktivnosti, pri čemu se komparativna prednost pojavljuje ukoliko je oportunitetni trošak proizvodnje određenog dobra niži u promatranoj zemlji u odnosu na njene trgovinske partmere (Krugman i Obstfeld, 2003., p. 12). Zemlje će ostvariti koristi od trgovine tako što će se specijalizirati u proizvodnji onih dobara za koje posjeduje komparativnu prednost, dok će se radna snaga kretati prema relativno učinkovitijim industrijama. Implikacije su pozitivne na agregatnoj i individualno na sektorskoj razini. Zemlje će ukupno ostvariti koristi iz trgovine, a distribucija dohotka neće biti narušena. U stvarnosti, uslijed trgovine dolazi do distorzija u distribuciji dohodaka iz barem dva razloga.

Prvo, promjene u proizvodnji rezultirati će i promjenama u potražnji. I na koncu, rad nije savršeno mobilan među industrijama. Unutar grupe modela „Ricardova“ tipa nastao je određen broj radova koji se bave istraživanjem teze kako su različite aktivnosti praćene različitim rastom produktivnosti zbog razlika u tehnologiji, iz čega proizlazi kako će zemlje specijalizirane u sektorima sa višim stopama produktivnosti postizati brži ukupan rast. Jedan primjer takvog modela je predstavljen u Grossman i Helpman (1991.). Autori zaključuju kako zemlje mogu upravljati obrascima specijalizacije u svrhu upravljanja rastom.

Kada se unutar teorije međunarodne trgovine razmatra utjecaj trgovine na konvergenciju, ne postoji zajedničko stajalište. Dio autora smatra kako će manje razvijene regije ostvariti koristi iz trgovine s razvijenijim regijama te konvergirati. Prednosti iz trgovine pojavljuju se u obliku prelijevanja znanja, dakle, uslijed trgovine s razvijenijim zemljama one manje razvijene koriste njihova znanja i tehnologije što je jednostavnije i brže od stvaranja inovacija i stoga konvergiraju. Međunarodna trgovina u manje razvijenim zemljama dovodi do jačanja ljudskog kapitala koji važna determinanta konvergencijskog procesa. Nezanemariv učinak očekuje se i od izjednačavanja cijena proizvodnih faktora (na tragu HOS modela) što također ide u prilog manje razvijenim regijama. S druge strane, dio autora smatra da međunarodna trgovina produbljava razlike u razvijenosti, naročito ako se radi o trgovini među regijama različitih razina razvoja. Ova skupina autora argumentira kako regijje u razvoju moraju razviti svoja gospodarstva prije nego se otvore međunarodnoj trgovini, inače će trgovina imati devastirajući učinak na njih (Zhang, 2006.). Također, dio autora smatra kako su učinci prelijevanja proizašli iz učenja kroz rad (eng.*learning by doing*) ograničeni na ekonomiju regije, a ne događaju se, kako neki tvrde, između regija. (Young, 1999.). Wood i Rodao-Cano (1999.) tvrde kako će se uslijed trgovine produbljavati razlike u specijalizacijskim strukturama na način da će manje razvijene regije proizvoditi sve više proizvoda koje će proizvoditi nekvalificirana radna snaga, dok će u razvijenijim regijama jačati proizvodnja proizvoda za koje je potrebna kvalificirana radna snaga. S obzirom na razlike u dohotcima za nekvalificiranu (eng. *unskilled labor*) i kvalificiranu radnu snagu (eng. *skilled labor*) te produbljavanje specijalizacije doći će do divergencije.

Kao što se može očekivati od jednostavne teorije regionalne trgovinske specijalizacije, mnogo toga ostaje neobjašnjeno kada se konfrontira sa stvarnim obrascima regionalne specijalizacije (Armstrong i Taylor, 2005., p. 124).

Određen teorijski napredak postignut je kroz Heckscher-Ohlinov (HO) faktorsko-proporcionalni model u kojem su u središtu razmatranja kretanja resursa kao izvora dvosmjerno korisne trgovine među zemljama. Model je ujedno poslužio za objašnjavanje specijalizacije regija pomoću kretanja proizvodnih faktora. Osnovni je model zasnovan na premisi kako će se zemlja specijalizirati u proizvodnji onog dobra za čiju proizvodnju ima (relativno) više proizvodnih faktora. U modelu postoje dva proizvodna faktora, rad i kapital, dvije regije i proizvode se dva dobra. Prema ovoj skupini modela, s obzirom na komparativne prednosti (u predtrgovinskoj fazi), uslijed međusobne trgovine zemalja, kretanje proizvodnih faktora determinirati će cjenovnu konkurentnost dobara u razmjeni. Slijedom navedenog, zemlja će se specijalizirati u proizvodnji onih dobara kod kojih može postići troškovnu učinkovitost, a konačan rezultat međunarodne trgovine je interindustrijska trgovina i rast diverzifikacije sektorskih struktura.

Brojni su teoretičari pokušali premostiti određena ograničenja predloženog modela, stoga je model doživio brojne preinake u smislu uvođenja dodatnih faktora proizvodnje, dodatnih roba koje su predmet trgovine i dodatnog broja zemalja. Inovativni modeli ipak nisu znatno doprinijeli u smislu objašnjenja promatranih činjenica (Sen, 2010.).

Najistknutiji ograničavajući faktor HOS modela, dakako je izostanak empirijske potvrde modelskih predviđanja (Sen, 2010.).

Unutar predstavljenog teorijskog pravca, nisu razmatrani utjecaji međunarodne trgovine na distribuciju dohodaka promatranih zemalja, odnosno, na njihovu potencijalnu konvergenciju. Unatoč određenim ograničavajućim pretpostavkama, ali i zaključcima, pokušaji razmatranja utjecaja trgovine na stopu rasta gospodarstva napravljeni su u radovima Johnson (1956.) i Bhagwati (1958.). Potonji zaključuje kako se uvjeti trgovine pogoršavaju u zemljama koje brže rastu u odnosu na njihove trgovinske partnere što nije u skladu s realim očekivanjima.

Zaključno, tradicionalna trgovinska teorija, unutar koje je proizvodnja utemeljena komparativnim prednostima, implicira promjene u sektorskoj strukturi zemlje, a pojava specijalizacije u proizvodnji smatrala se jedinim izvorom međunarodne trgovine (Bernard, et al., 2007.). Na tom tragu, trgovina untar ovog teorijskog pravca smatrala se interindustrijskom, odnosno, držalo se da će zemlje (regije) ostvarivati uvoz i izvoz dobara iz međusobno različitih industrija.

Kako tradicionalna trgovinska teorija bazirana na strani ponude ekonomije nije mogla ponuditi objašnjenje za rast trgovine relativno sličnih trgovinskih partnera i intraindustrijske trgovine, 1980-ih godina, razvili su se novi koncepti razmatrajući potražnu stranu gospodarstva bazirani na Dixit-Stiglitzovom (1977.) modelu monopolističke konkurencije u kojem potrošači preferiraju raznolikost ponude proizvoda.

Glavni zaokreti u odnosu na tradicionalnu teoriju međunarodne trgovine napravljeni su u smislu uvođenja rastućih prinosa, kao i na davanju važnosti benefitima ostvarenim kroz međunarodnu trgovinu.

Unutar ove grupe teorijskih pristupa, zajedničkog naziva **nova trgovinska teorija** (eng. *new international trade theory*), neposrednost je instrument pomoću kojeg poduzeća eksploatiraju učinke ekonomije obujma i rasta tržišnog udjela, a zbog diferencijacije proizvoda dolazi do porasta intraindustrijske trgovine, odnosno trgovine proizvoda koji se mogu smatrati bliskim supstitutima (Krugman, 1980.). Rezultat intraindustrijske trgovine je specijalizacija u proizvodnji različitih varijanti istih proizvoda. Uklanjanje trgovinskih barijera, omogućava daljnju eksploataciju ekonomija obujma, međutim, za razliku od neoklasičnih koncepata rasta, ne dolazi do znatnih promjena u sektorskim strukturama (Krugman, 1981.).

U sklopu nove trgovinske teorije kasnije su se razvili modeli koji razmatraju utjecaj ukupne veličine tržišta, promjena u veličini tržišta, kretanje proizvodnih faktora, transportne troškove te ekonomije obujma na razinu međunarodnih aktivnosti među gospodarstvima (Barrios Cobos et al., 2000.) Zagovornici ovog teorijskog pravca smatraju kako će multinacionalna poduzeća, s obzirom na navedene čimbenike, premještati svoje aktivnosti među zemljama (regijama) i tako utjecati na njihove ekonomske performanse. Glavni učinci evidentirati će se kroz konvergenciju u strukturi njihove potražnje i industrijskoj strukturi, kako multinacionalna poduzeća razmještaju proizvodnju. Unutar ovog teorijskog pravca zadržana je premisa kako će učinci prelijevanja znanja i premještanja tehnologije dovesti do smanjenja razlika u dohotcima, no nema govora o pojavi konvergencije u beta ili sigma terminima (Cyrus, 2004.).

Potrebno je dodati kako do sada opisani teorijski pravci u svojim osnovnim inačicama, odnosno početnim fazama razvoja, nisu razmatrali utjecaj trgovine na distribuciju dohotka promatranih zemalja, odnosno na njihovu moguću konvergenciju.

Svojevrstan iskorak u odnosu na trgovinsku teoriju ponudio je Porter (1990.) koji u svom radu predlaže novi teorijski pravac koji treba komparativnu prednost zamijeniti konkurentskom prednošću. Autor analizira konkurentnost zemlje i utjecaj međunarodne trgovine na njenu agregatnu produktivnost. Pri tom zaključuje kako zemlja uključena u međunarodne trgovinske tijekove može imati pozitivan, ali i devastirajući učinak trgovine na produktivnost. Koristi od trgovine mogu se eksploatirati tako što će se zemlja specijalizirati u onim industrijama u kojima postiže veću produktivnost, dok bi proizvode iz sektora u kojima je manje produktivna trebala uvoziti. Na tragu MAR eksternalija, (detaljnije opisanih u poglavlju 2.3), autor zaključuje kako preljevanjima znanja pogoduje okruženje specijalizirane, prostorno ograničene industrije. Autor ekonomski sustav vidi kao „dijamant nacionalne prednosti“ sačinjen od četiri komponente koje determiniraju kokurentsku prednost zemlje (grafički prikaz 10). Determinante nacionalne (regionalne) konkurentnosti obuhvaćaju:

- uvjete potražnje - tržište koje potiče korištenje ekonomije obujma i razvoj inovacija;
- uvjete proizvodnje - specijalizirane faktore proizvodnje;
- strategiju poduzeća, strukturu i konkurenciju - kontekst koji potiče napredak;
- povezane i potporne institucije - interakcije među dionicima iste industrije koje potiču na rast inovativnosti i produktivnosti.

Navdeni elementi međusobno se potiču i generiraju kumulativnu uzročnost. Uloga države je stvaranje okruženja koje pogoduje poduzećima da ostvare konkurentsku prednost.

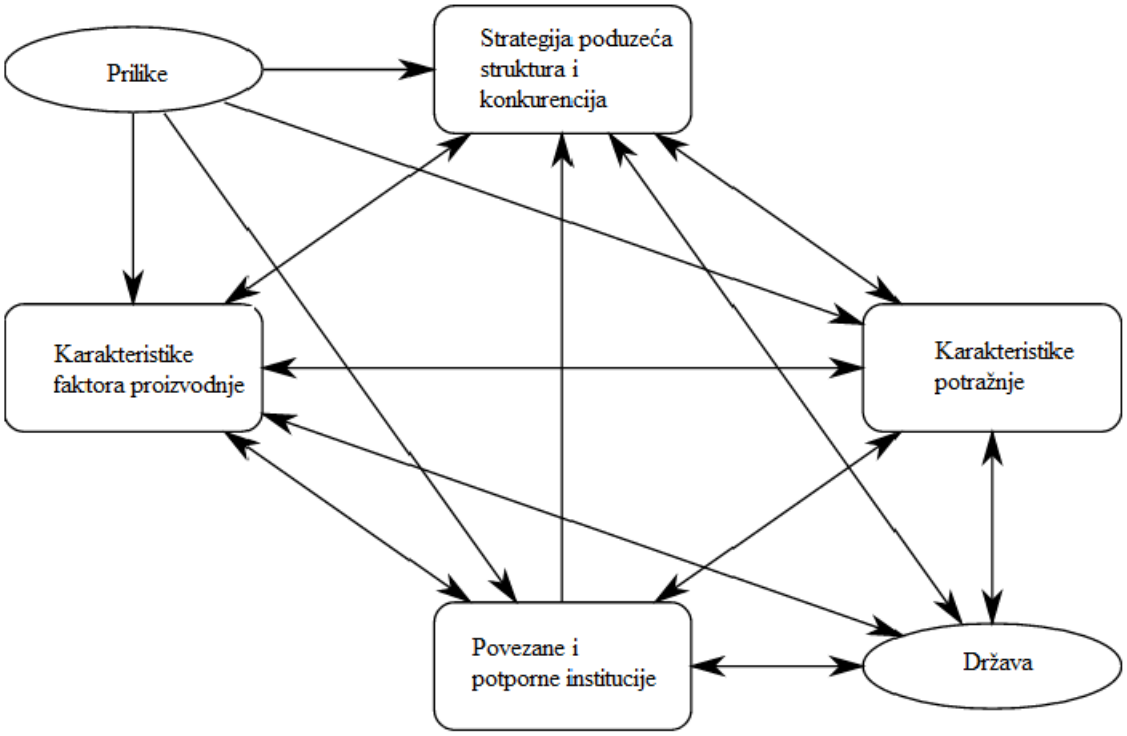


**Grafički prikaz 10: Determinante konkurentske prednosti**

Izvor: Prikaz autora prema Porter (1990)

Sistematičnost konteksta nacionalne (regionalne) konkurentnosti ove vrste čini ga teško ponovljivim (Öz, 2000.). Drugim riječima, nije realno očekivati repliku uspješnih kontekstualnih rješenja iz jednog sustava u drugi, stoga brojni autori osporavaju vrijednost predloženog koncepta kao relevantnog barem iz perspektive političkih implikacija.

Iako je Porterov pristup višestruko kritiziran, osim navedenog, naročito zbog izostanka matematičke formulacije što ga čini empirički teško dokazivim, iz perspektive ovog rada može se smatrati vrijednim pažnje obzirom na činjenicu da ukazuje gospodarsku strukturu kao determinantu regionalne uspješnosti.

Endogenizacija veličine tržišta u uvjetima nesavršene konkurencije, aglomeracijske ekonomije i rastućih prinosa iznjedrila je novi zaokret u teorijskom poimanju specijalizacije unutar koncepta nove ekonomske geografije. Glavne implikacije koncepta **Nove ekonomske geografije** proizašle iz modela jezgre i periferije su pojava učinka „veličine tržišta“ (eng. *home market effect*) iz kojeg proizlazi da se industrije lociraju u blizini velikih tržišta uslijed čega se smanjuju transportni

troškovi i što u konačnici dovodi do aglomeriranja ekonomske aktivnosti. Učinak veličine tržišta iz perspektive gospodarske strukture implicira određeni stupanj specijalizacije, tako će regije s većim brojem stanovništva biti neto izvoznici industrijskih proizvoda, dok će manje regije biti neto izvoznici poljoprivrednih dobara (p. 113, Fujita i Thisse, 2009.).

Kao što je ranije navedeno (u poglavlju 2.6.), ključne determinante za nastanak aglomeracijske ekonomije unutar koncepta Nove ekonomske geografije su transportni troškovi i naročito mobilnost radne snage, a o njihovim razinama ovisi konačan rezultat na ukupnu ekonomsku aktivnost (Puga, 1999.).

Polazišna osnova ovog teorijskog pravca je rad Krugmana (1991.) u kojem postoje dvije regije i dva sektora, pri čemu u poljoprivrednom sektoru djeluju konstantni prinosi, a u sektoru industrijske proizvodnje djeluju rastući prinosi. Također, u modelu jezgra-periferija postoje dvije skupine radne snage, poljoprivredna i proizvodna. Proizvodni sektor proizvodi beskonačno mnogo varijanti horizontalno diferenciranih proizvoda, svaka od kojih je proizvedena od zasebnih proizvođača, koristeći rad kao jedini faktor proizvodnje. S druge strane, poljoprivredni sektor proizvodi homogena dobra, a poljoprivredna radna snaga je jedini proizvodni faktor. Radna snaga u proizvodnji savršeno je mobilna, dok u poljoprivrednom sektoru nije. Konačno, u trgovini industrijskim proizvodima pojavljuju se tranportni troškovi na koje djeluje učinak ledenjaka (eng. *iceberg*). Modelom se ilustrira kako interakcije rastućih prinosa, transportinih troškova i mobilnosti proizvodnih faktora mogu dovesti do prostorne promjene u ekonomskoj strukturi (Fujita, Mori, 2005.). Na prostornu distribuciju ekonomske aktivnosti djeluju centrifugalne (imobilnost radnika poljoprivrednih dobara) i centripetalne sile (cirkularna uzročnost veza prema naprijed i prema natrag). Ukoliko prevladaju centripetalne sile, regija će se specijalizirati u proizvodnji industrijskih dobara. Formalizirani oblik modela predstavljen je u radu Krugmana (1991.).

Zadovoljstvo potrošača slijedi Cobb-Douglasovu funkciju:

(4.1.) $U = C_M^{\mu} C_A^{1-\mu}$,

Jednadžbom je opisana funkcija koristi svih potrošača unutar ekonomije, pri čemu je $C_A$ potrošnja poljprivrednih dobara, dok je $C_M$ agregatna potrošnja industrijskih dobara. Udio potrošnje

industrijskih dobara predstavljen je s $\mu$ što je ujedno ključni parametar koji determinira da li će regije konvergirati.

Agregatna potrošnja industrijskih dobara opisana je jednadžbom:

(4.2.)

$$C_M = \left[\sum_{t=1}^{N} c_t^{(\sigma-1)/\sigma}\right]^{\sigma/(\sigma-1)}$$

Pri čemu je $N$ velik broj potencijalnih proizvoda, a $\sigma > 1$ je elastičnost supstitucije među proizvodima te je ujedno drugi parametar koji determinira ravnotežu u modelu.

Uz pretpostavke o dvije regije, dva sektora s pripadajućim (jednim) faktorom, seljaci proizvode poljoprivredna dobra uz jednu jedinicu uloženog rada. Stoga je ponuda poljoprivrednog rada $(1-\mu)/2$ u svakoj regiji. Seljaci su imobilna radna snaga, dok se radnici u proizvodnji kreću među regijama. Količina ponude radnika u proizvodnji $L_1$i $L_2$ ukupno čini $\mu$:

(4.3.) $L_1 + L_2 = \mu$.

Proizvodnja pojedinog industrijskog dobra $i$ funkcija je fiksnog i konstantnog marginalnog troška, rezultat čega je ekonomija obujma opisana jednadžbom:

(4.4.) $L_{Mi} = \alpha + \beta x_i$

Pri čemu je $L_{Mi}$ rad korišten u proizvodnji dobra $i$, a $x_i$ je finalni proizvod.

Dvije važne pretpostavke odnose se na trgovinu:

- Transportni trošak poljoprivrednih dobara je nula;
- Transportni trošak za industrijska dobra poprimaju formu „ledenjaka“.

Prva pretpostavka osigurava jednaku cijenu poljoprivrednih dobara i jednak profit seljaka u obje regije, dok je transportni trošak industrijskih proizvoda uključen u cijenu transportiranog dobra. Konkretno, u trgovini između regija od svake jedinice transportiranog industrijskog dobra, samo

dio ($\tau < 1$) dođe do druge regije. Pri tom, frakcija $\tau$ koja predstavlja inverzni indeks transportnih troškova je posljednji parametar koji determinira da li će regije konvergirati.

Kako poduzeća nastoje maksimizirati svoj profit, cijena je određena pomoću elastičnosti potražnje, transportnih opadajućih troškova i proizvodne funkcije:

(4.5.) $p_1 = \left(\frac{\sigma}{\sigma-1}\right)\beta w_1$,

Pri čemu je $w_1$ plaća radnika u industriju u regiji 1, i slična jednadžba se primjenjuje na regiju 2. Uzevši u obzir da je ulazak u industriju slobodan, profiti teže nuli:

(4.6.) $(p_1 - \beta w_1)x_1 = \alpha w_1$ ,

(4.7.) $x_1 = x_2 = \alpha(\sigma - 1)/\beta$.

Na ovaj način postavljena proizvodnja po poduzeću, neovisna je o visini nadnica, uvjetima potražnje i drugo. Iz toga slijedi kako je količina proizvedenih dobara proporcionalna broju radnika:

(4.8.) $\frac{n_1}{n_2} = \frac{L_1}{L_2}$.

Kako bi se uvela dinamička komponenta u model, pretpostavlja se kretanje radnika prema regijama s višim nadnicama. U skladu s time, pojaviti će se konvergencija ako se nadnice industrijskih i poljoprivrednih radnika izjednačavaju. Ukoliko se rad kreće prema jednoj regiji, pojaviti će se divergencija u dohotcima.

Kako bi se odredilo stanje ravnoteže u kratkom roku, potrebno je razmotriti ponašanje relativne potražnje za reprezentativnim proizvodom:

(4.9.) $\frac{c_{11}}{c_{12}} = \left(\frac{p_1\tau}{p_2}\right)^{-\sigma} = \left(\frac{w_1\sigma}{w_2}\right)^{-\sigma}$

Pri čemu je $c_{11}$ potrošnja u regiji 1 reprezentativnog prozvoda iz regije 1, a $c_{12}$ je potrošnja u regiji 1 reprezentativnog proizvoda regije 2. Cijena lokalnog proizvoda ne uključuje druge troškove, dok cijena proizvoda iz druge regije uključuje transpotrni trošak ($p_2/\tau$).

Udio potrošnje regije 1 na lokalne u odnosu na uvozne proizvode prikazan je sa $z$.

(4.10.) $z_{11} = \left(\frac{n_1}{n_2}\right)\left(\frac{p_1\tau}{p_2}\right)\left(\frac{c_{11}}{c_{12}}\right) = \left(\frac{L_1}{L_2}\right)\left(\frac{w_1\tau}{w_2}\right)^{-(\sigma-1)}$

(4.11.) $z_{12} = \left(\frac{L_1}{L_2}\right)\left(\frac{w_1\tau}{w_2}\right)^{-(\sigma-1)}$

Iz navedenog parametra proizlaze dvije implikacije. Prvo, uslijed porasta relativnih cijena u regiji 1 za 1%, dok relativna količina potrošnje pada za $\sigma$ posto, vrijednost potrošnje pasti će za $\sigma - 1$ posto zbog efekta cijena. Drugo, kako se proizvodi više proizvoda u regiji 1, veći je udio potrošnje za bilo koju razini relativnih cijena.

Ukupan dohodak radnika regije 1 jednak je ukupnoj potrošnji u obje regije (4.12.), dok je dohodak u regiji 2 predstavljen izrazom (4.13.):

(4.12.) $w_1L_1 = \mu\left[\left(\frac{z_{11}}{1+z_{11}}\right)Y_1 + \left(\frac{z_{12}}{1+z_{12}}\right)Y_2\right]$;

(4.13.) $w_2L_2 = \mu\left[\left(\frac{1}{1+z_{11}}\right)Y_1 + \left(\frac{1}{1+z_{12}}\right)Y_2\right]$.

Dohotci dvije regije ovise o distribuciji radnika i njihovim nadnicama:

(4.15.) $Y_1 = \frac{1-\mu}{2} + w_1L_1$

(4.16.) $Y_2 = \frac{1-\mu}{2} + w_2L_2$

U izrazima (4.11.)-(4.16.) opisan je sustav koji determinira visinu nadnica u obje regije. Kretanje rada među regijama može imati dvojake učinke na relativan odnos nadnica $w_1/w_2$. Uslijed djelovanja učinka veličine tržišta, *ceteris paribus*, nadnice će biti više u regijama s većim tržištem. S druge strane, prevelika konkurencija na takvim tržištima može proces okrenuti u suprotnom smjeru.

U dugom roku doći će do pojave nižih cijena industrijskih proizvoda u regijama s više stanovnika. Indeks cijena industrijskih proizvoda određen je udjelom radne snage u industriji $f = L_1/\mu$ u regiji 1:

(4.17.) $P_1 = \left[ f w_1^{-(\sigma-1)} + (1-f)\left(\frac{w_2}{\tau}\right)^{-(\sigma-1)} \right]^{-1/(\sigma-1)}$

(4.18.) $P_2 = \left[ f\left(\frac{w_1}{\tau}\right)^{-(\sigma-1)} + (1-f) w_2^{-(\sigma-1)} \right]^{-1/(\sigma-1)}$

Izraz (4.17.) predstavlja indeks cijena industrijskih proizvoda za rezidente regije 1, dok se izrazom (4.18.) opisuje indeks cijena industrijskih proizvoda za rezidente regije 2. Iz navedenog proizlaze realne nadnice u svakoj od regija:

(4.19.) $w_1 = w_1 P_1^{-\mu}$

(4.20.) $w_2 = w_2 P_2^{-\mu}$

Neto priljev radnika u regiju 1 će rezultirati padom indeksa cijena u regiji 1 i rastom u regiji 2 što će se odraziti na rast realnih nadnica u regiji 1 u odnosu na regiju 2. Relativna promjena u realnim nadnicama uzrokovati će dodatnu divergenciju među regijama.

Regije su simetrične kada vrijedi $f = \frac{1}{2}$, odnosno kada postoji jednak broj radnika pri jednakim realnim nadnicama. Ravnotežno stanje je održivo samo ako $w_1/w_2$ pada zajedno sa udjelom radne snage u industriji $(f)$ jer će radnici migrirati iz regije s većim brojem regija, u tom slučaju nastupiti će regionalna konvergencija. U protivnom, kada $w_1/w_2$ raste zajedno s udjelom radne snage u industriji, radnici će migrirati u regiju u kojoj već ima više radnika, stoga dolazi do divergencije.

Osnovni model, predviđa mogućnost pojave aglomeracije i deglomeracije neovisno o inicijalnim uvjetima (Eckey i Kosfeld, 2004.). Ukupno gledano, da li će doći do konvergencije ili divergencije ovisi o nekoliko čimbenika. S jedne strane, učinci veličine tržišta i indeksa cijena djeluju u smjeru divergencije. S druge pak strane, razina konkurencije na poljoprivrednom tržištu djeluje u smjeru konvergencije. Konačan rezultat ovisi o tome koji učinci prevladaju.

Iako je postigao izuzetnu pozornost i popularnost, kritičari koncepta Nove ekonomske geografije zamjeraju mu pretjeranu matematičku formulaciju, navodeći kako model ima „premalo regija, a previše matematike“ stoga mu se pripisuje sindrom „pogreške identiteta“ (Martin, 1999.). Osim

navedenog, kritičari modela NEG ukazuju na njegovu ograničenu primjenjivost naglašavajući sljedeće nedostatke (Eckey i Kosfeld, 2004.):

- Zanemarivanje intertempolarne dimenzije u odlukama poduzeća i kućanstava što je važno svojstvo suvremenih teorija potrošnje i investicija;
- Zanemarivanje ponašanja konkurentskih poduzeća prilikom određivanja cijena;
- Poduzeća proizvode jedno dobro i nije moguće postići učinak ekonomije širine (eng. *economies of scope*);
- Poduzeća su savršeno mobilna neovisno o fiksnim troškovima;
- Jedini faktor proizvodnje je rad, kapital je zanemaren;
- Jedini faktor koji ima ograničavajući učinak na aglomeraciju su trasportni troškovi, pri tom se zanemaruje ujecaj porasta cijena nekretnina, preopterećenosti infrastrukture ili negativnih utjecaja na okoliš;
- Radnici su mobilni samo među regijama, ali ne i među sektorima;
- Zanemarivanje transportnih troškova za poljoprivredna dobra;
- Neobjašnjeni su obrati u uspješnosti regija.

Navdena ograničenja moguće je premostiti uvođenjem sljedećih pretpostavki (Eckey i Kosfeld, 2004.):

- Transportni troškovi za poljoprivredna dobra;
- Učinci regionalnih prelijevanja;
- Sektor netrživih usluga (eng. *non-tradable services*);
- Ograničena mobilnost radne snage.

Navedene kritike rezultirale su brojnim pokušajima modifikacije standardnog modela kako bi bolje odgovarao stvarnosti (Eckey i Kosfeld, 2004.). U narednom periodu nastao je određen broj radova unutar Nove ekonomske geografije, međutim, u središtu pozornosti više nije mobilnost radnika, već vertikalne veze među poduzećima. Primjerice, Venables (1996.) je modificirao Krugmanov model u cilju analize interindustrijskih veza tako što je uveo dvije industrije u obliku monopolističke konkurencije, koje karakteriziraju uzlazno-silazne putanje. Koncentracija trgovine industrijskim proizvodima u jednoj od dvije identične regije rezultirati će koristima za poduzeća u usponu, jer se nalaze na lokaciji s mnogo poduzeća u silaznoj putanji i stoga mogu

jeftinje opskrbljivati potrošače. S druge strane, poduzeća u silaznoj putanji imati će koristi od lokacije u kojoj se nalaze mnoga poduzeća u usponu jer im to smanjuje trošak proizvodnih faktora.

Krugman i Venables (1996.) analiziraju da li će rastuća integracija učiniti zemlje sličnijima u njihovim gospodarskim strukturama. Industrije karakteriziraju intraindustrijske veze, odnosno proizvodnja dobara koji se mogu koristiti u potrošnji i u daljnjoj proizvodnji. Dakle, svaka se industrija u određenoj mjeri oslanja na drugu industriju kao dobavljača, ali istodobno koristi je kao dobavljača intermedijarnih dobara za vlastitu proizvodnju. Rad je savršeno mobilan stoga će se kretati među sektorima u potrazi za najvećim dohotkom. S ovakvim postavkama industrijska struktura je jednaka u obje zemlje dok su transportni troškovi visoki. Uslijed snižavanja transportnih troškova, snažne intraindustrijske veze dovode do specijalizacije (Schmutzler, 1999.).

***

Opisani su brojni teorijski pristupi koji iz različitih kuteva razmatraju promjene u sektorskim strukturama i implikacije specijalizacije na pojavu aglomeracije, koncentracije i konvergencije. Kako bi se donio definitivan sud o utemeljenosti navedenih pristupa, potrebno je razmotriti rezultate empirijskih istraživanja.

## 4.2 Definiranje pojma i kvantifikacija specijalizacije regija

Pojam regionalne specijalizacije ocrtava regionalnu perspektivu distribucije sektorskih udjela u ukupnom gospodarstvu, najčešće u usporedbi s ostatkom zemlje. Regija se smatra visoko specijaliziranom ako je u njoj zastupljen mali broj industrija koje zajedno imaju visok udio u sektorskoj strukturi (Goschin et al., 2009.). Regije su zbog svoje relativne veličine više specijalizirane od država. Općenito, što je promatrana teritorijalna razina niža, to je razina specijalizacije veća (Marelli, 2007.).

Mjerenju specijalizacije može se pristupiti na nekoliko načina. Najčešće korištena mjera specijalizacije regija je specijalizacijski koeficijent ili kako ga neki autori nazivaju Krugmanov indeks specijalizacije (KSI):

(4.21.) $SPE_i^K = \sum_{j=1}^{m} \left| q_{i,j} - \overline{q_{\iota,j}} \right|$

(4.22.) $q_{i,j} = \frac{X_{i,j}}{\sum_{j=1}^{m} X_{i,j}}$

(4.23.) $\bar{q}_{i,j} = \frac{\sum_{k \neq i}^{n} X_{kj}}{\sum_{k \neq i}^{n} \sum_{j=1}^{m} X_{kj}}$

Pri čemu je $X_{kj}$dodana vrijednost tržišnih cijena u regiji $i$ u sektoru $j$ tako da $i = 1,2, \dots, n$, a $j = 1,2, \dots, m$. $SPE_i^K$ razmatra proizvodnu strukturu promatrane regije u odnosu na druge regije. U slučaju $q_{i,j} = \overline{q_{\iota,j}}$ indeks je 0, u protivnom, ako su strukture potpuno različite indeks poprima vrijednost 2.

Iz prve jednadžbe moguće je izračunati ukupnu specijalizaciju promatranog područja:

(4.24.) $ESP^K = \sum_{i=1}^{n} w_i SPE_i^K$

Pri čemu je $w_i$ ponder dodijeljen regiji $i$ s obzirom na veličinu ili populacije ili gospodarstva, a $\sum_{i=1}^{n} w_i = 1$.

Opisanim pristupom moguće je promatrati razinu i i kretanje regionalne specijalizacije u proizvodnji, međutim nije informativan iz perspektive određenih dinamika distribucije indeksa. Tako primjerice, relativne promjene u sektorskoj strukturi među regijama ili grupiranje regija slične proizvodne strukture koje se odvajaju od drugih regija mogu ostati skrivene.

Navedeno ograničenje moguće je premostiti primjenom metodologije predstavljene u radovima Quaha (1996. b, 1997. a). Na početku, potrebno je procijeniti funkciju gustoće za odgovarajuću distribuciju indeksa specijalizacije. Da bi se izbjeglo navođenje funkcionalnog oblika unaprijed, najbolje je koristiti neparametrijske tehnike procjene. Naposlijetku, da bi se dobilo korisne informacije o promjenama moguće je na distribuciju primjeniti tranzicijske matrice. Međutim, kako su rezultati osjetljivi s obzirom na proizvoljno postavljen broj razreda sugerira se primjeniti

stohastičke jezgre koje odražavaju vjerojatnosti tranzicije između hipotetski beskonačnog broja razreda.

Jedna od najčešće korištenih mjera specijalizacije je lokacijski Ginijev koeficijent, deriviran iz prostorne Lorenzove krivulje (Kim, et al., 2000.). Formalizirano lokacijski Gini računa se za regiju $m$ kako slijedi:

(4.25.)

$$G_m = \frac{\Delta}{4\bar{\mu}_x};$$

Gdje su:

(4.26.)

$$\Delta = \frac{1}{n(n-1)} \sum_{i=1}^{n} \sum_{j=1}^{n} |x_i - x_j|$$

Pri čemu je $n$ broj jedinica, a $i$ i $j$ su pojedine jedinice ($i \neq j$), a $x_{i(j)}$:

(4.27) $x_{i(j)} = \frac{Udio\ zaposlenih\ u\ m\ za\ i(j)}{Udio\ u\ ukupnoj\ zaposlenosti\ i(j)}$

(4.28.) $\bar{\mu}_x = \sum_{i=1}^{n} x_i \ \div n$

Vrijednost koeficijenta je nula kako je zaposlenost u sektoru $m$ distribuirana jednako kao ukupna zaposlenost, a vrijednost je 0,5 ako je sektorska zaposlenost u potpunosti koncentrirana u jednoj jedinici.

Koeficijent pruža informacije o stupnju koncentracije određenog sektora i omogućava usporedbu razine koncentracije, odnosno disperzije među sektorima. Međutim, u slučaju visoke vrijednosti koeficijenta otkriva se samo jedna dimenzija aglomeracije, dakle, koncentracija sektora $m$ u ograničenom broju jedinica. Geografska dimenzija ostaje skrivena, sektori mogu biti grupirani u klaster(e) ili ravnomjerno raspoređeni u prostoru. U oba slučaja, vrijednost je nepromijenjena.

Prilikom bilateralne komparacije sektorske strukture regija moguće je upotrijebiti Finger-Kreinin indeks kao mjeru sličnosti sektorskih struktura ili njegov komplement, indeks različitosti (eng. *dissimilarity index*):

(4.29.) $DIS_r = 1 - \sum_i min(s_{i,r}, s_{i,0})$

Pri čemu se $r$ odnosi na regiju, a 0 na ukupno promatrano područje. Indikator je moguće primijeniti na ukupnu zaposlenost, industrijski sektor i usluge.

Još jedan od pokazatelja koji se može koristiti za mjerenje specijalizacije je Herfindahl-Hirschmanov indeks:

(4.30.)

$$H_i^S = \sum_{j=1}^{m} (g_{ij}^s)^2$$

(4.31.)

$$g_{ij}^S = \frac{X_{ij}}{\sum_{j=1}^{m} X_{ij}} = \frac{X_{ij}}{X_i}$$

Pri čemu su $i$ regije, $j$ sektori, a $X$ dodana vrijednost ili zaposlenost. $X_{ij}$ je bruto dodana vrijednost ili zaposlenost sektora $j$ u regiji $i$, $X_j$ je ukupna bruto dodana vrijednost ili zaposlenost u regiji $i$, dok je $g_{ij}^S$ udio sektora $j$ u ukupnoj vrijednosti regije $i$.

Vrijednost indeksa raste s porastom razine specijalizacije. Najviša hipotetska vrijednost indeksa je 1 kada je regija specijalizirana u samo jednom sektoru. S druge strane, najniža razina specijalizacije $\frac{1}{m}$ pojavila bi se u situaciji kad bi svi sektori imali jednak udio u regiji $j$. Navedeno implicira osjetljivost rezultata na broj opservacija što ograničava njegovu primjenu za usporedbe rezultata što mu je ujedno najistaknutiji nedostatak. Drugi nedostatak ovog indeksa proizlazi iz činjenice što je Herfindahl-Hirschmanov indeks apsolutna mjera stoga veće regije više utječu na rezultat, što ga čini pristranim u korist većih regija.

Za izučavanje promjena u sektorskim strukturama može se primijeniti Lilienov indeks koji mjeri brzinu promjena realokacije zaposlenosti među sektorima, kao glavni čimbenik razlika u specijalizaciji (Lilien, 1982.). Računa se individualno za svaku $i$ regiju kako slijedi:

(4.32.)

$$L_i^S = \sqrt{\sum_{j=1}^{m} \frac{X_{ij}}{X_i} (\Delta log X_{ij} - \Delta log X_i)^2}$$

Pri čemu je $\frac{X_{ij}}{X_i}$ udio regije $j$ u ukupnoj zaposlenosti regije $i$, a $\Delta$ je operator prve direfencije. Veća vrijednost ovog indeksa označava brže strukturne promjene i veću realokaciju rada između sektora. Pomoću ovog pokazatelja moguće je ustanoviti i fleksibilnost gospodarstva da odgovori na promjene u agregatnoj potražnji. Tumačenju vrijednosti indeksa treba pristupiti s oprezom obzirom na njegovu potencjalnu korelaciju s učincima agregatnih cikličkih poremećaja.

Za istraživanje promjena sektorskih ili teritorijalnih udjela u različitim jedinicama vremena moguće je primijeniti i koeficijent apsolutnih strukturnih promjena:

(4.33.)

$$\tau_{g_1 - g_0} = \sqrt{\frac{\sum_{i=1}^{n} (g_{1i} - g_{0i})^2}{n}}$$

Pri čemu su $g_{1i}$ i $g_{01}$ sektorski ili regionalni udjeli $i$ u vremenskim točkama 0 i 1. Vrijednost koeficijenta je veća što je veći intenzitet promjena u specijalizaciji.

Kako bi se istražio **odnos specijalizacije i konvergencije**, potrebno je primijeniti jednadžbu kondicionalne konvergencije:

(4.34.) $(ln\, y_{r,t+\tau} - ln\, y_{r,t})/\tau = \alpha + \beta\, ln\, y_{r,t} + y\, x_{r,t} + \varepsilon$

Gdje je $x_{r,t}$ „strukturalna“ varijabla. U ovom slučaju, za istraživanje konvergencije svake regije prema njenom stanju ravnotežnom stanju kao „strukturalnu“ varijablu moguće je koristiti:

- pokazatelj specijalizacije (KSI ili DSI), odnosno, pokazatelj njihove promjene tijekom vremena (ΔKSI ili ΔDIS);
- sektorske udjele (poljoprivrede, industrije ili usluga) u ukupnoj zaposlenosti.

### 4.3 Specijalizacija regija u EU

Koliko su teorijski pristupi kojima se analizira odnos konvergencije i specijalizacije različiti, kao što je prikazano u prethodnoj cjelini, utoliko postoji i čitav niz empirijskih pristupa za istraživanje navedenog odnosa. U nastavku će biti prikazani rezultati empirijskih istraživanja s obzirom na opisane teorijske pravce.

Puga (1999) na tragu postavki NEG analizira da li će ekonomska integracija regija dovesti do aglomeriranja industrija u prostoru i kakav će to imati učinak na distribuciju dohodaka. Rezultati istraživanja ukazuju na visoku osjetljivost rezultata s obzirom na razinu mobilnosti radnika, međutim ona je u EU ograničena. Autor zaključuje kako aglomeracija industrije podiže nadnice na lokacijama gdje se nalazi mnogo poduzeća ukoliko se radnici realociraju prema industrijaliziranim regijama eliminirajući dohodovne nejednakosti. Međutim, u slučaju izostanka migracije dispariteti će egzistirati. Slično istraživanje proveli su Brülhart i Torstensson (1996.) koji su pronašli dokaze koji podupiru tezu obrnute „U“ veze između stupnja regionalne integracije i prostorne aglomeracije. Autori zaključuju kako su se u ranim stadijima integracije u EU aktivnosti s višom razinom ekonomije obujma koncentrirale u geografskim jezgrama, dok se tijekom 1980. godina koncentracija u jezgrama smanjila.

Molle (1996.) provodi svoje istraživanje na 96 NUTS I i NUTS II regija između 1950. i 1990. razmatrajući produktivne sektorske strukture s varijablom zaposlenosti. Autor nalazi kako regionalne strukture konvregiraju tijekom vremena. Također, nalazi kako su najiše specijalizirane regije one na periferiji. Slično istraživanje provodi Hallet (2002.) koji za varijablu koristi dodanu vrijednost. Istraživanjem je obuhvaćeno119 NUTS I i NUTS II regija u periodu 1985.-1995. Autor zaključuje kako tijekom promatranog perioda regionalna specijalizacija opada i da se u čak 85 jedinica kreće prema prosjeku Europske unije. Također, nalazi se da poljoprivreda i

pripadajuća joj prerađivačka industrija imaju tendenciju disperzirati se u prostoru, dok industrijsku proizvodnu karakterizira geografska koncentracija.

Midelfart-Knarvik et al. (2000.) u izvješću pripremljenom za Europsku komisiju istražuju promjene u industrijskoj proizvodnji za 13 zemalja OECD i Irsku na razini 36, odnosno 27 sektora (Irska), u periodu od 1970. do 1997. godine. Autori zaključuju sljedeće:

- Većina europskih zemalja imala je prisutan proces konvergencije industrijskih struktura tijekom 1970-ih, a taj trend je preokrenut u ranim 1980-im kada je došlo do znatne divergencije;
- Najizraženije promjene u industrijskoj strukturi dogodile su se u Irskoj i Finskoj gdje je došlo do ekspanzije u visoko tehnološkim industijama. Ovaj proces u manjoj mjeri prisutan je u svim promatranim zemljama;
- Inicijalno dislocirane industrije pokazuju tendenciju prostorne koncentracije. To se uglavnom odnosi na sporo rastuće i industrije nisko kvalificirane radne snage, čiji je relativni pad praćen s koncentracijom, uobičajeno u perfifernim područjima niskih nadnica;
- Među industrijama koje su inicijalno bile prostorno koncentrirane, oko polovina ih je ostala prostorno koncentriranima, dok se određena disperzija pojavila u dijelu industrije srednje i visoke tehnologije te u sektorima relativno visokog rasta, koje pokazuju disperziju izvan zemalja središnje Europe;
- Usluge su generalno više disperzirane od proizvodnje. Dva su prisutna trenda: smanjenje udjela proizvodnje u korist udjela usluga i sustizanje manje razvijenih zemalja sa inicijalno niskom razinom udjela usluga;
- Prisutan je proces divergencije u industrijskim strukturama, a industrije su i manje koncentrirane.

Autori su također identificirali sile koje determiniraju industrijsku lokaciju i nalazi se da visoka prostorna varijabilnost u industrijskim strukturama može biti objašnjena kombinacijom troškovnih i geografskih čimbenika:

- Industrije u kojima su intenzivni I&R kreću se u smjeru lokacija koje obiluju istraživačima;

- Lokacije industrija za koje nije karakterističan fizički intenzivan rad tijekom cijelog perioda je pokazuju senzitibilnost na udio radne snage sa srednjim i visokim obrazovanjem;
- Lokacije s industrijama sa snažnim vezana prema naprijed i natrag osjetljive su na čimbenik centar-periferija. Lokacije centra privlače industrije gornje razine dodane vrijednosti (npr. industrije visoko ovisne o intermedijarnim proizvodima);
- Industrije s visokim stupnjem ekonomije obujma smještene su u lokacijama centra, iako ovaj učinak opada s vremenom.

Prikazani rezultati konzistentni su sa sličnim istraživanjima, primjerice Brülhart i Torstensson (1996.), Amiti (1999.), OECD (1999.), WIFO (1999.).

Ezcurra et al. (2004.) istražuju produktivnu specijalizaciju regija Europske unije u periodu između 1977. i 1999. godine. Između ostalog, autori pronalaze pozitivnu korelacijsku vezu između specijalizacije i mjera nejednakosti i polarizacije u regionalnim *per capita* dohotcima. Dapače, produktivna specijalizacija u snažnijoj je vezi s regionalnom polarizacijom, nego s nejednakostima. Rezultati istraživanja sugereiraju kako su promjene u regionalnoj specijalizaciji usko povezane s evolucijom dohodaka po stanovniku u Uniji tijekom promatranog perioda. Dodatno, autori zaključuju kako je specijalizacija u inverznom odnosu s veličinom regija. Istraživajući čimbenike specijalizacije nalaze kako regije udaljenije od jezgre više odstupaju od prosjeka u sektorskim strukturama, a one specijaliziranije se grupiraju u klastere.

Osim istraživanja na razini Europske unije, brojni istraživači primjenili su sličnu metodologiju na podatke zemalja članica Unije individualno. U pravilu, s nižom teritorijalnom razinom vezuje se viša razina specijalizacije. Rezultati istraživanja vrlo su osjetljivi na metodološke promjene. Osim teritorijalne razine, razina klasifikacije sektora također može imati snažan utjecaj na reuzulat istraživanja.

# 5. REZULTATI EMPIRIJSKOG ISTRAŽIVANJA

Uvažavajući postavljene ciljeve istraživanja i potrebu za testiranjem istraživačkih hipoteza rada sa svrhom pridonošenja razumijevanju odnosa **realne konvergencije regija i njihove sektorske specijalizacije,** prostor Europske unije, preciznije 28 zemalja članica, odabran je kao područje analize, ne samo zbog značaja za Republiku Hrvatsku, već i zbog naglašenog pristupa regionalnom razvoju u smislu posvećenosti gospodarskoj homogenizaciji teritorija, kao i istodobne opredjeljenosti specijalizaciji regija kao potecijalnog ključa za koheziju regija.

Istraživanje se provodi na regionalnoj razini Europske unije i sukladno tome naslanja se na teritorijalne jedinice za statistiku, odnosno NUTS klasifikaciju regija[13]. NUTS klasifikaciju ustrojio je Eurostat prije 30 godina i predstavlja statističku podjelu europskog teritorija na teritorijalne jedinice za razvoj regionalnih statistika i za ciljanje političkih intervencija na regionalnoj razini.

**S obzirom na raspoložive podatke, analizom je inicijalno obuhvaćeno 28 zemalja članica, odnosno 247 (osnovnih) NUTS II regija. Promatrani period odnosi se na 14-godišnje razdoblje od 2000. do 2013. godine.**

Sektorska specijalizacija naslanja se na NACE klasifikaciju, statističku klasifikaciju ekonomske aktivnosti u Europskoj uniji. [14] NACE je četveroznamenkasta klasifikacija koja pruža okvir za sakupljanje i obradu velikog broja statističkih podataka prema ekonomskoj aktivnosti za različite segmente ekonomske statistike (proizvodnja, zaposlenost i nacionalni računi) i druge statističke segmente razvijene unutar Europskog statističkog sustava - EES, eng. *European statistical sytem.*

[13] eng. *„Nomenclature of territorial units for statistics“*
[14] fra. *Nomenclature statistique des activités économiques dans laCommunauté européenne*

Kao glavni izvor podataka korištena je baza podataka EUROSTAT-a, generalne i regionalne statistike s obzirom na predmet istraživanja i to:

- Podaci o BDP-u *per capita*;
- Podaci o populaciji (i promjenama populacije);
- Podaci o sektorskoj specijalizaciji regija (prema broju zaposenih i bruto dodanoj vrijednosti);
- Ostali relevantni podaci s obzirom na teorijske postavke (podaci o udjelu visoko obrazovanih, podaci o fiksnom kapitalu, podaci o ulaganjima u istraživanje i razvoj).

Iz navedenih podataka izvedeni su:

- grupe sektorske specijalizacije regija sukladno metodologiji EUROSTAT-a;
- Herfindahl-Hirschmanov indeks specijalizacije regija;
- Indeks specijalizacije regija po pojedinom sektoru korišten u radu Cambridge Econometrics (2012).

Kao što je ranije navedeno sektori specijalizacije regija su grupirani, i to u pet skupina prema metodologiji EUROSTAT-a kako slijedi:

- poljoprivreda, eng. *agriculture, forestry and fishing* (**NACE sekcija A**)
- industrija, eng. *industry* (**NACE sekcije B–E)**
- građevinarstvo, eng. *construction* (**NACE sekcija F**)
- tržišne usluge, eng. *market services* (**NACE sekcije G–N**)
- javne i druge usluge, eng. *public administration and public services, arts, entertainment and recreation, repair of household goods and other services* (**NACE sekcije O–U**)

Istraživanje se konceptualno bazira na dva različita prisupa. Kao zavisna varijabla u oba pristupa koristi se BDP po stanovniku. Prvim pristupom, uvjetno rečeno, zanemaruje se sektorska specijalizacija regija, odnosno razmatra se samo opća razina specijalizacije regija. Varijabla koja se pri tom koristi za mjerenje specijalizacije regija odnosi se na Herfindahl-Hirschmanov indeks specijalizacije regija koji govori o razini sektorske specijalizacije u određenoj regiji, međutim, iz

njega nije razvidna specijalizacija po pojedinim sektorima. Herfindahl-Hirschmanov indeks kalkuliran je kako na podacima o broju zaposlenih u sektoru, tako i na podacima o bruto dodanoj vrijednosti u sektorima. Kao kontrolne varijable korišteni su podaci o promjeni populacije, ljudskom kapitalu (udio visokoobrazovanih), ulaganju u istraživanje i razvoj (R&D), investicijama (GFC).

Drugim pristupom razmatra se konvergencija regija mjerena bruto domaćim proizvodom po stanovniku, dok se kao kontrolne varijable koriste indeksi specijalizacije po odabranih pet skupina sektorske specijalizacije, također na podacima o bruto dodanoj vrijednosti i broju zaposlenih po sektorima. Obzirom da odabrana mjera specijalizacije razmatra specijaliziranost regije u odnosu na prosječnu vrijednost sektorske specijalizacije, kao referentna vrijednost korišteni su i nacionalni i europski prosjek sektorske specijalizacije.

Pokazatelji i načini njihova izračuna korišteni u prvom i drugom pristupu dati su u tablici 12.

**Tablica 2: Pokazatelji specijalizacije**

| Pokazatelj | Definicija | Izvor |
|---|---|---|
| Herfindahl-Hirschmanov indeks[15] | $H_i^S = \sum_{j=1}^{m} (g_{ij}^s)^2$<br>$g_{ij}^S = \frac{X_{ij}}{\sum_{j=1}^{m} X_{ij}} = \frac{X_{ij}}{X_i}$<br>$H_i^S$ – Herfindahl-Hirschmanov indeks specijalizacije<br>$i$ - regija, $j$ - sektor<br>$X$ - dodana vrijednost ili zaposlenost<br>$X_{ij}$- je bruto dodana vrijednost ili zaposlenost sektora $j$ u regiji $i$<br>$X_j$ - je ukupna bruto dodana vrijednost ili | Goschin, et al. (2009) |

[15] Vrijednost indeksa raste s porastom razine specijalizacije. Najviša hipotetska vrijednost indeksa je 1 kada je regija specijalizirana u samo jednom sektoru. S druge strane, najniža razina specijalizacije $\frac{1}{m}$ pojavila bi se u situaciji kad bi svi sektori imali jednak udio u regiji $j$.

| | | |
|---|---|---|
| | zaposlenost u regiji $i$<br>$g_{ij}^{S}$ - udio sektora $j$ u ukupnoj vrijednosti regije $i$. | |
| Indeks specijalizacije[16] | $S_{ij} = \frac{\frac{E_{ij}}{\sum_{j=1}^{n} E_{ij}}}{\frac{\sum_{i=1}^{m} E_{ij}}{\sum_{j=1}^{n}\sum_{i=1}^{m} E_{ij}}}$<br>$S_{ij}$ – indeks specijalizacije<br>$i$ - regija, $j$ - sektor<br>$E$ - zaposlenost ili bruto dodana vrijednost | Cambridge Econometrics (2012) |

Izvor: Prikaz autora

Empirijskim istraživanjem testirana je utemeljenost teorijskih postavki na stvarnim podatcima te se nastojala ispitati točnost postavljenih hipoteza.

Glavna hipoteza glasi: **Realna konvergencija regija Europske unije uvjetovana je njihovom specijalizacijom.**

Pomoćne hipoteze su:

H1 – Specijalizacija regija Europske unije utječe na razinu produktivnosti istih

H2 - Razlike u produktivnosti među regijama rezultat su razlika u produktivnosti među sektorima njihovih specijalizacija.

H3 – Regije specijalizirane za financijske i poslovne usluge te regije specijalizirane u sektorima visoke dodane vrijednosti ostvaruju više stope rasta u odnosu na ostale regije.

H4 – Poljoprivredne regije i regije zastarijele industrijske proizvodnje ostvaruju niže stope rasta.

[16]Veća koncentracija zaposlenosti, odnosno bruto dodane vrijednosti u sektoru $j$ od nacionalnog / EU prosjeka implicira vrijednost indeksa veću od 1.

Testiranje prve pomoćne hipoteze bazira se na formuliranju modela uvažavajući razlike u razinama specijalizacije mjerene Herfindahl-Hirschmanovim indeksom, što implicira razlike u produktivnostima regija. Zavisna varijabla u modelu je rast BDP-a po stanovniku, a jedna od nezavisnih je BDP po stanovniku iz razdoblja $t-1$.[17] Kao dodatne kontrolne varijable korištene su varijable: rast populacije, ulaganje u fiksni kapial, ulaganje u istraživanje i razvoj te udio visoko obrazovanih. Varijable su odabrane temeljem najzastupljenijih teorijskih koncepata rasta. Fiksni kapital i rast populacije imaju uporište u neoklasičnom teorijskom konceptu rasta nastalom na radovima Solowa (1956.) i Swana (1956.), dok se varijable ulaganje u istraživanje i razvoj i udio visoko obrazovanih (ljudski kapital) naslanja na endogene teorije rasta proizašle iz radova Romera (1986., 1990.), Lucasa (1988.), Grossman i Helpmana (1991.) te Aghion i Howitta (1998.). Varijablom specijalizacije mjerene Herfindahl-Hirschamnovim indeksom nastoji se ispitati utemeljenost teze da će razina specijalizacije djelovati na regionalni rast kao i snaga utjecaja varijable. Ova teza pojavljuje se u radovima teoretičara "nove teorije rasta" (prema Smithu) te Kaldorovoj (1970.) izvoznoj teoriji prema kojoj otvaranje izvozu vodi većoj specijalizaciji što otvara mogućnost za rast produktivnosti. Pri tom se ne razmatra u kojem se sektoru regija specijalizira, već da li se specijalizira, neovisno o prirodi specijalizacije (Dalum, et al., 1999.), dok rast produktivnosti proizlazi iz učenja.

Druga pomoćna hipoteza naslanja se na drugi predstavljeni pristup istraživanju kojim se ispituje odnos produktivnosti regija i razlika u produktivnostima sektora. Ovaj pristup ima uporište u "Rikardijanskom" pogledu prema kojem je bitno u kojem se sektoru regije specijaliziraju obzirom da svi sektori nemaju jednak potencijal rasta. Razlozi tome mogu će pronaći na potražnoj strani (različita dohodovna elastičnost između različitih aktivnosti), kao i na strani ponude, odnosno, različitim tehnološkim mogućnostima.

Detaljnijijim ispitivanjem u svrhu potvrđivanja robusnosti rezultata, pristupa se testiranju treće i četvrte hipoteze koje objedinjuju i neoklasični i naročito endogeni koncept rasta. Postavljene hipoteze također imaju uporište u konceptu Nove ekonomske geografije u kojem različite aktivnosti (industrijske i poljoprivredne) generiraju različite učinke na gospodarstvo. U interakciji

[17] Iako je uobičajeno da se kao mjera produktivnosti koristi bruto dodana vrijednost po zaposlenom, BDP po stanovniku odabran je iz razloga što bolje odražava ukupno stanje ekonomije.

djelovanja različitih sila, faktori proizvodnje se razmještaju u prostoru, a konačan učinak ovisan je o tome koje će sile, centrifugalne ili centripetalne, prevagnuti.

Empirijsko ispitivanje treće i četvrte hipoteze sintetizira opisana dva pristupa istraživanju, stoga će empirijski model sadržavati i odabrane sektore specijalizacije i pomoćne kontrolne varijable poput ljudskog kapitala, investicija i dr.

Odabir varijabli jedan je od ključnih momenata empirijskog istraživanjam stoga je ovoj fazi potrebno pristupiti s posebnim oprezom. Recentna empirijska istraživanja koriste različite kontrolne varijable za formulaciju modela rasta i ispitivanje njihova odnosa s rastom. Kontrolne varijable odabiru se s obzirom na raspoložive podatke i prostorne jedinice koje su predmetom istraživanja., a u skladu s prethodnim komplementarnim istraživanjima. (Durlauf, Quah, 1999.) Prema Levine i Renelt (1992) preko 50 varijabli pokazalo se signifikantno koreliranim sa rastom u barem jednom regresijskom istraživanju. U ovom radu varijable su stoga odabrane s obzirom na cilj i svrhu istraživanja te uvažavajući do sada postignuta teorijska i empirijska dostignuća.

## 5.1 Metodološki aspekti empirijskog istraživanja

Odabrana metodologija istraživanja odnosi se na panel analizu rasta prema modelu uvjetne konvergencije.

Panel predstavlja niz opažanja koji se ponavljaju kroz određeni vremenski period kroz odabrane (prostorne) jedinice. Prednosti korištenja panela u odnosu na analizu vremenske serije i prostornu regresiju razvidne su kroz veću informativnost, prezentiranje više varijabilnosti, manje kolinearnosti među varijablama, više stupnjeva slobode i veću učinkovitost (Arbia, Piras, 2005.). Također, uporabom panela omogućava se kontroliranje individualne heterogenosti.

Metodološki okvir naslanja se na prostorni regresijski model opisan izrazom:

(5.1.) $y_{t,i} = \alpha + \beta y_{t,i} + \varepsilon_i$

Pri čemu je $y_{t,i}$ zavisna varijabla, za regiju $i$ u vremenu $t$, $\alpha$ je konstantan član, $\beta$ je koeficijent promjene dok su izrazom $\varepsilon_i$ obuhvaćene slučajne varijable.

Dinamička panel verzija jednadžbe rasta može biti opisana izrazom:

(5.2) $ln\left(\frac{y_{t,i}}{y_{t-1,i}}\right) = \alpha_i + \beta\ ln\ (y_{t-1,i}) + \varepsilon_{i,t}$;

$i = 1, \dots, N;\ t = 1, \dots, T$

Pri čemu $i$ označava regije u vremenu $t$. Zavisna varijabla $ln\left(\frac{y_{t,i}}{y_{t-1,i}}\right)$ se odnosi na godišnji rast bruto domaćeg proizvoda po stanovniku, dok je izrazom $ln\ (y_{t-1,i})$ opisana vrijednost bruto domaćeg proizvoda po stanovniku u vremenu $t-1$. Vremenski nepromjenjiva komponenta sadržana je u $\alpha_i$ i obuhvaća specifične regionalne učinke koji nisu eksplicitno obuhvaćeni regeresijskom jednadžbom, dakle, sve neobuhvaćene čimbenike koji utječu na proces rasta. Parametre $\alpha$ i $\beta$ potrebno je procijeniti.

## 5.2 Analiza podataka i rezultati empirijskog istraživanja

Uvažavajući predstavljeni metodološki okvir kao i ciljeve istraživanja pristupa se ispitivanju odnosa sektorske specijalizacije regija u svrhu utvrđivanja empirijskog modela kojim se sumira utjecaj odabranih varijabli na regionalni rast u Europskoj uniji.

Prilikom utvrđivanja empirijskog modela nastojalo se zadovoljiti pretpostavke analize, što uključuje podudaranje s teorijskim i logičkim očekivanjima predznaka i jačine veze, kako za konvergenciju, tako i za odabrane kontrolne varijable. Rezultat je sumiran u tablici 3.

**Tablica 3: Model između jedinica promatranja, Europska unija NUTS II razina, 2000-2013**

| Zavisna varijabla rast log_BDP *per capita* | | |
|---|---|---|
| **Nezavisne varijable** | | **P > \| t \|** |
| log_GDP per capita_(t-1) | -0.0287951 | *(0.000)* |
| HHI_va | 0.0154679 | *(0.097)* |
| Higheducation | 0.0007701 | *(0.000)* |
| Populationgrowth | -0.0004751 | *(0.020)* |
| Constant | 0.2962419 | *(0.000)* |
| | | |
| Broj opažanja | 2728 | |
| R-squared | 0.6513 | |
| SD | 0.0141744 | |

Izvor: EUROSTAT, STATA, izračun autora

U ovom modelu, ali i drugim dinamičkim panel modelima koji će biti prikazani u radu, zavisna varijabla je rast regionalnog BDP-a *per capita*, a jedna od nezavisnih varijabli je BDP *per capita* u razdoblju $t-1$. Odnos zavisne varijable, rasta regionalnog BDP-a *per capita*, i nezavisne vijable, BDP-a *per capita* u razdoblju $t-1$ predstavlja odnos stope rasta gospodarstva s obzirom na razinu BDP-a *per capita* regije iz prethodnog razdoblja što odgovara konceptu **beta konvergencije**. Drugim riječima, negativan predznak uz dati koeficijent varijable BDP-a *per capita* u razdoblju $t-1$ predstavlja brzinu kretanja regija prema njhovim ravnotežnim stanjima.

Za ostale varijable vrijedi sljedeće: pozitivan predznak uz koeficijent odgovara pozitivnom utjecaju promatrane varijable na promjenu zavisne varijable, dakle, pozitivan predznak uz koeficijent ukazuje na pozitivan učinak varijable na regionalni rast. S druge strane, negativan predznak uz koeficijent predstavlja negativan utjecaj promatrane varijable na zavisnu varijablu, odnosno na regionalni rast.

Predstavljeni model između jedinice promatranja (eng. *Between effects*) (Tablica 3) ukazuje na prisutnost realne konvergencije mjerene BDP-om po stanovniku i to po stopi od 2,9% što je u skladu s teorijskim i empirijskim očekivanjima. Zbog same specifikacije modela u kojem je zavisna varijabla rast BDP *per capita*, a jedna od nezavisnih varijabli BDP-a *per capita* u razdoblju $t-1$, nije bilo potrebno koristiti dinamičku verziju panel modela.

Specijalizacija mjerena Herfindahl_Hirschmanovim indeksom za bruto dodanu vrijednost po sektorima ima pozitivan utjecaj na rast BDP-a po stanovniku pri razini signifikantnosti od 10%. Također, u skladu s očekivanjima udio visoko obrazovanih u populaciji također ima pozitivan utjecaj na rast BDP-a po stanovniku, dok varijabla rast populacije ima blagi negativan utjecaj na regionalni rast. Negativan utjecaj rasta populacije na rast može se objasniti učinkom raspršivanja rasta BDP-a po stanovniku kako raste populacija. Za očekivati je da bi s dužim periodom promatranja uzorka ova varijabla poprimila pozitivan predznak.

U svrhu potvrđivanja robusnosti rezultata, odnosno predstavljenog modela, pristupilo se istraživanju alternativnih modela, uvrštavajući druge potencijalne kontrolne varijable. Ispitivanje robusnosti rezultata predstavljeno je u tablicama 4 i 5.

Modeli su podijeljeni s obzirom na to koju varijablu koriste za izračun Herfindahl-Hirschmanovog indeksa, bruto dodanu vrijednost ili udio zaposlenih po sektorima. U skupini modela koja sektorsku specijalizaciju mjeri Herfindahl-Hirschmanovim indeksom prema udjelu zaposlenih po sektorima, specijalizacija (HHI_em) ima relativno jak pozitivan utjecaj na regionalni rast, dok se konvergencija mjerena BDP-om po stanovnku kreće između 2 i 6%, a prosječna stopa iznosi 4%. Od ostalih varijabli korištenih u modelima, promjena populacije ima relativno blagi značaj na rast BDP-a po stanovniku s dvojakim predznacima što vjerojatno ukazuje na potrebu promatranja dužeg roka od raspoloživog. Dvojaki rezultati opažaju se i za varijablu ulaganje u istraživanje i razvoj (GERD) što također može biti posljedica kratkog roka promatranja uzorka. Isključivo pozitivni učinci zapažaju se kod varijabli udio visoko obrazovanih u populaciji te investicijama (log_GFC). Detaljan pregled modela nalazi se u prilogu (Ispisi iz STATA-e 1-6).

U drugoj skupini modela, onoj u kojima se specijalizacija mjeri Herfindahl-Hirschmanovim indeksom po udjelu bruto dodane vrijednosti po sektorima također je potvrđena prisutnost

konvergencije i to čak većom brzinom nego je to slučaj s prethodno predstavljenim modelima. Stope konvergencije u ovim modelima kreću se između 2 i 6%, s tim da je veći broj modela sa stopama na gornjoj granici, a prosječna stopa iznosi 5,6%. Varijabla specijalizacije mjerena Hefindahl-Hirschmanovim indeksom (HHI_va) ima relativno jak pozitivan utjecaj u svim modelima. Od ostalih varijabli, u skladu s očekivanjima, pozitivne predznake imaju varijable udio visoko obrazovanih, investicije te ulaganje u istraživanje i razvoj s nešto slabijom jačinom veze. Ponovno, varijabla promjene populacije ima različite predznake u modelima. Detaljan pregled ovih modela nalazi se u prilogu (Ispisi iz STATA-e 7-13).

**Tablica 4: Modeli utjecaj odabranih varijabli na rast BDP-a po stanovniku NUTS II regija Europske unije**

| Varijable | Zavisna varijabla rast log_BDP per capita | | | | | |
|---|---|---|---|---|---|---|
| | M1 | M2 | M3 | M4 | M5 | M6 |
| | GLS random effects | GLS random effects - Swamy Arora estimator | Between effects - Weighted least square | ML random effects | ML random effects - noconstant | ML random effects – noconstant |
| log_GDP per capita (t-1) | -0.0538285<br>(0.000) | -0.0618732<br>(0.000) | -0.0340031<br>(0.000) | -0.0490285<br>(0.000) | -0.0207413<br>(0.000) | 0.0210918<br>(0.000) |
| HHI_em | 0.0808624<br>(0.000) | 0.060505<br>(0.007) | 0.0580235<br>(0.000) | 0.0791121<br>(0.000) | 0.1413362<br>(0.000) | 0.1624519<br>(0.000) |
| High_education | | | 0.0004939<br>(0.047) | | | |
| Population_change | 0.0014905<br>(0.000) | 0.001941<br>(0.000) | | 0.0012577<br>(0.000) | -0.0010339<br>(0.003) | |
| log_GFC | 0.0143693<br>(0.000) | 0.0140932<br>(0.000) | 0.0043247<br>(0.041) | 0.0121665<br>(0.000) | 0.0241053<br>(0.000) | 0.0253212<br>(0.000) |
| GERD | | 0.000114<br>(0.080) | | | | -0.000383<br>(0.000) |
| _constant | 0.4139174<br>(0.000) | 0.4905792<br>(0.000) | 0.3071774<br>(0.000) | 0.3879748<br>(0.000) | | |
| Razdoblje | 2000-2013 | 2000-2013 | 2000-2013 | 2000-2013 | 2000-2013 | 2000-2013 |
| Broj regija | 160 | 160 | 160 | 160 | 160 | 160 |
| Ukupan broj opažanja | 1457 | 1233 | 1433 | 1457 | 1457 | 1233 |
| R2 | | | | | | |
| within | 0.2262 | 0.2211 | 0.1727 | | | |
| Between | 0.4321 | 0.4753 | 0.6066 | | | |
| Overall | 0.1890 | 0.2062 | 0.1686 | | | |
| * U zagradama su vrijednosti t-statistike | | | | | | |

Izvor: EUROSTAT, STATA, izračun autora

**Tablica 5: Modeli utjecaj odabranih varijabli na rast BDP-a po stanovniku NUTS II regija Europske unije**

| Varijable | Zavisna varijabla rast log_BDP per capita | | | | | | |
|---|---|---|---|---|---|---|---|
| | M1 | M2 | M3 | M4 | M5 | M6 | M7 |
| | GLS random effects | GLS random effects | GLS random effects - Swamy Arora estimator | ML random effects | ML random effects | Between effects - Weighted least square | GLS random effects - Swamy Arora estimator |
| log_GDP per capita (t-1) | -0.0620471 (0.000) | -0.0620471 (0.000) | -0.0635314 (0.000) | -0.0620471 (0.000) | -0.055982 (0.000) | -0.0287951 (0.000) | 0.0585779 (0.000) |
| HHI_va | 0.0738867 (0.000) | 0.0738867 (0.000) | 0.0753232 (0.000) | 0.0738867 (0.000) | 0.0603521 (0.001) | 0.0154679 (0.097) | 0.0626181 (0.001) |
| High_education | | | | | 0.0006214 (0.013) | 0.0007701 (0.000) | 0.0006183 (0.019) |
| Population_change | 0.0017536 (0.000) | 0.0017536 (0.000) | 0.0018171 (0.000) | 0.0017536 (0.000) | 0.0016334 (0.000) | -0.0004751 (0.020) | 0.0017772 (0.000) |
| log_GFC | 0.0093983 (0.000) | 0.0093983 (0.000) | 0.0099688 (0.000) | 0.0093983 (0.000) | 0.0084211 (0.000) | | 0.0095045 (0.000) |
| GERD | 0.000015 (0.007) | 0.000015 (0.007) | 0.000154 (0.007) | 0.000015 (0.007) | | | |
| _constant | 0.5244054 (0.000) | 0.5244054 (0.000) | 0.5330416 (0.000) | 0.5244054 (0.000) | 0.4739583 (0.000) | 0.2962419 (0.000) | 0.4886857 (0.000) |
| Razdoblje | 2000-2013 | 2000-2013 | 2000-2013 | 2000-2013 | 2000-2013 | 2000-2013 | 2000-2013 |
| Ukupan broj opažanja | 1295 | 1295 | 1295 | 1295 | 1499 | 2728 | 1499 |
| Broj regija | 161 | 161 | 161 | 161 | 161 | 220 | 161 |
| R2 | | | | | | | |
| within | 0.2287 | 0.2287 | 0.2303 | | | 0.0671 | 0.2397 |
| Between | 0.5913 | 0.5913 | 0.5869 | | | 0.6513 | 0.5837 |
| Overall | 0.2142 | 0.2142 | 0.2142 | | | 0.141 | 0.1904 |
| * U zagradama su vrijednosti t-statistike | | | | | | | |

Izvor: EUROSTAT, STATA, izračun autora

Presjekom predstavljenih skupina modela uočava se da su stope konvergencije približno slične, da je u svim modelima identificirana snažna pozitivna veza sektorske specijalizacije i regionalnog rasta. Od ostalih varijable stabilne su (s istim predznacima) udio visoko obrazovanih i investicije, dok se za varijable ulaganje u istraživanje i razvoj (GERD) te promjenu populacije uočavaju dvojaki rezultati s obzirom na predznak.

Presjek skupina modela s pripadajućim predznacima varijabli ukazuje na dobar odabir modela s obzirom na to da je u svim modelima potvrđena pozitivna veza varijabli specijalizacije, investicija, udjela visoko obrazovanih s rastom BDP *per capita*, dok je za promjenu populacije prisutna konzistentna dvojakost predznaka, što je već objašnjeno kratkoćom vremenske serije.

**Tablica 6: Usporedba dobivenih modela**

| **Varijabla** | **Modeli sa specijalizacijom s obzirom na udio zaposlenih po sektorima (Employment)** | **Modeli sa specijalizacijom s obzirom na udio u bruto dodanoj vrijednosti (GVA)** |
|---|---|---|
| | **Predznaci koeficijenata** | |
| HHI | **+** | **+** |
| High_education | **+** | **+** |
| GERD | **+/-** | **+** |
| Log_GFC | **+** | **+** |
| Population_growth | **+/-** | **+/-** |

Izvor: Prikaz autora

Potrebno je naglasiti kako je inicijalno napravljen daleko veći broj modela od predstavljenih, međutim, isti su odbačeni prilikom identifikacije irelevantnosti određenih varijabli (na razini signifikantnosti do 10%) ili uslijed nezadovoljavajućih predznaka za određene varijable.

Nadalje, u svrhu daljnjeg ispitivanja robusnosti modela pristupilo se daljnjem ispitivanju odnosa regionalnog rasta i specijalizacije alternativnim pristupom koji razmatra pojedinačne sektore specijalizacije regija u svrhu ispitivanja utjecaja pojedine sektorske specijalizacije na rast BDP-a *per capita*. Specijalizacija se razmatra s obzirom na pet skupina sektorske specijalizacije grupiranih prema metodologiji EUROSTAT-a kako slijedi: **poljoprivreda**, eng. *agriculture, forestry and fishing* (NACE sekcija A), **industrija**, eng. *industry* (NACE sekcije B–E), **građevinarstvo**, eng. *construction* (NACE sekcija F), **tržišne usluge**, eng. *market services* (NACE sekcije G–N), **javne i druge usluge**, eng. *public administration and public services, arts, entertainment and recreation, repair of household goods and other services* (NACE sekcije O–U). Korištena mjera specijalizacije je indeks specijalizacije korišten u radu Cambridge Econometrics (2012).

Unutar ovog pristupa korištena zavisna varijabla je rast BDP *per capita,* a prva nezavisna varijabla, kao i ranije, BDP *per capita* iz razdoblja $t-1$. Ostale zavisne varijable odnose se na indekse specijalizacije po pet navedenih sektora, razmatrano s obzirom na zaposlenost i bruto dodanu vrijednost, a referentne vrijednosti za izračun indeksa specijalizacije su i europski i nacionalni prosjeci udjela sektora. Pri tom se nisu razmatrali modeli u kojima parcijalno utjecaj imaju samo neki sektori, već je kriterij bio da su varijablama obuhvaćeni indeksi specijalizacije po svim sektorima kako bi se zadovoljio uvjet da cjelokupna slika o specijalizaciji u regijama bude obuhvaćena modelom.

Među dobivenim modelima uočava se nekonzistentnost u predznacima, te koeficijenti konvergencije od 2,2 do 4,6%. U prva tri modela, te M6 (osim sektora građevinarstva) oučavaju se negativni predznaci za sve varijable, što može ukazivati na negativno djelovanje razine specijalizacije na rast. Ova pojava može se objasniti efektom gubitka specijalizacije kako se regije razvijaju, a onda na višim razinama razvoja usporavaju svoj rast, što je u skladu s teorijskim postavkama rasta. Atipična vrijednost koeficijenta konvergencije od 15% nalazi se u modelu M4 stoga je ovaj model odbačen kao neprimjenjiv. Nadalje, model M5, za razliku od modela M1, M2 i M3 sadrži pozitivne predznake za sve varijable što ukazuje na isti zaključak. Vrijednosti koeficijenata, pri tom, sugeriraju na različite produktivnosti sektora, što implicira da je za rast važno u kojem se sektoru regija specijalizira. Tako će primjerice, regije specijalizirane u sektoru tržišnih usluga ostvarivati veće stope rasta od regija specijaliziranih u poljoprivredi.

**Tablica 7: Modeli utjecaj odabranih varijabli na rast BDP-a po stanovniku NUTS II regija Europske unije**

| Varijable | Zavisna varijabla rast log_BDP per capita | | | | | | |
|---|---|---|---|---|---|---|---|
| | M1 | M2 | M3 | M4 | M5 | M6 | M7 |
| | va_eu | va_eu | va_eu | va_eu | va_eu | va_eu | em_na |
| | GLS random effects - Swamy Arora estimator | Between effects | Between effects - Weighted least square | Fixed effects | ML random effects noconstant | ML random effects | ML random effects noconstant |
| log_GDP per capita (t-1) | -0.0453937<br>(0.000) | -0.0329906<br>(0.000) | -0.0330466<br>(0.000) | -0.1509574<br>(0.000) | -0.0289317<br>(0.000) | -0.0464482<br>(0.000) | -0.0220513<br>(0.000) |
| Sij_agriculture | -0.0079047<br>(0.000) | -0.0058634<br>(0.000) | -0.0058610<br>(0.000) | -0.0047851<br>(0.082) | 0.0040475<br>(0.000) | -0.0080585<br>(0.000) | 0.0172775<br>(0.000) |
| Sij_industry | -0.0173409<br>(0.023) | -0.0143385<br>(0.089) | -0.0141640<br>(0.093) | 0.0308987<br>(0.051) | 0.0686844<br>(0.000) | -0.0176300<br>(0.024) | 0.0584892<br>(0.000) |
| Sij_construction | -0.0070484<br>(0.068) | -0.0077907<br>(0.073) | -0.0075794<br>(0.084) | 0.0660356<br>(0.000) | 0.0401149<br>(0.000) | 0.0079892<br>(0.062) | -0.0238603<br>(0.020) |
| Sij_market_services | -0.0306356<br>(0.019) | -0.0335722<br>(0.019) | -0.0333985<br>(0.020) | -0.0581578<br>(0.066) | 0.1205456<br>(0.000) | -0.0304390<br>(0.024) | 0.1254868<br>(0.000) |
| Sij_public_services | -0.0323966<br>(0.000) | -0.0343012<br>(0.000) | -0.0340966<br>(0.000) | -0.0275197<br>(0.014) | 0.0401477<br>(0.000) | -0.0322852<br>(0.000) | 0.0775646<br>(0.000) |
| _constant | 0.5817363<br>(0.000) | 0.475677<br>(0.000) | 0.4753078<br>(0.000) | 1,516943<br>(0.000) | | 0.5912485<br>(0.000) | |
| Razdoblje | 2000-2013 | 2000-2013 | 2000-2013 | 2000-2013 | 2000-2013 | 2000-2013 | 2000-2013 |
| Ukupan broj opažanja | 2333 | 2333 | 2333 | 2333 | 2333 | 2333 | 1620 |
| Broj regija | 182 | 182 | 182 | 182 | 182 | 182 | 196 |
| R2 | | | | | | | |
| within | 0.2482 | 0.1799 | 0.1824 | 0.2931 | | | |
| Between | 0.6620 | 0.6967 | 0.6968 | 0.5775 | | | |
| Overall | 0.2194 | 0.2098 | 0.2101 | 0.1903 | | | |
| * U zagradama su vrijednosti t-statistike | | | | | | | |

Izvor: EUROSTAT, STATA, izračun autora

Osim predznaka koeficijenata koji su u dobivenim modelima dvojaki, veličina procijenjenih koeficijenata također ukazuje na to da je za rast bitno u kojim sektorima je regija specijalizirana. Pri tom na rast više utječu sektori tržišnih i javnih usluga te industrija, dok je utjecaj poljoprivrede i građevinarstva manje robustan. Ukupno gledano, modeli proizašli iz ovog pristupa također ukazuju na prisutnost konvergencije NUTS II regija Europske unije.

Rezultati istraživanja komplementarni su s brojnim empirijskim istraživanjima koji ukazuju ne samo na prisutnost umjerene konvergencije u Europskoj uniji, već i da je za rast važna specijalizacijska struktura po sektorima (Kemeny, T., Storper, M., 2012). Unutar ovog pristupa razlike u rezultatima ukazuju na to da je za konvergenciju važniji koncept apsolutne konvergencije od relativne. Ova pojava usko je povezana s veličinom jedinice promatranja, regije, stoga produktivnost relativno veće regije ima robusnije rezultate unatoč relativno manjoj apsolutnoj konvergenciji zbog učinaka kroz povezane sektore.

## 5.3 Ocjena istraživačkih hipoteza

Interpretacija svih predstavljenih modela ukazuje na to da je regionalni rast BDP-a po stanovniku u snažnoj vezi s razinom regionalnog BDP-a po stanovniku iz prethodnog razdoblja što potvrđuje prisutnost konvergencije regija Europske unije na NUTS II razini. Primjenom dva različita pristupa istraživanja prisutnosti i brzine konvergencije, u svim modelima ispitan je i utjecaj razine sektorske specijalizacije, odnosno strukture sektorske specijalizacije, kako bi se potvrdila (ili odbacila) teza o relevantnosti specijalizacije za regionalni rast. U prvom pristupu razmatran je utjecaj opće razine specijalizacije mjerene Herfindahl-Hirschmanovim indeksom na regionalni rast, a rezultat su pozitivni koeficijenti uz varijablu kojom je opisana specijalizacija. Modelima dobivenim unutar ovog pristupa potvrđena je prva pomoćna hipoteza prema kojoj specijalizacija regija utječe na razinu produktivnosti istih. Kako bi se rezultat dodatno potvrdio, izrađeni su modeli koji specijalizaciju mjere s obzirom na broj zaposlenih u sektoru i s obzirom na bruto dodanu vrijednost po sektorima. Drugim pristupom razmatrana je konvergencija regija mjerena bruto domaćim proizvodom po stanovniku, dok su kao kontrolne varijable korišteni indeksi specijalizacije po odabranih pet skupina sektorske specijalizacije. Modelima proizašlim iz primjene ovog pristupa potvrđena je druga pomoćna hipoteza prema kojoj su razlike u

produktivnosti regija rezultat razlika u produktivnostima među sektorima njihovih specijalizacija. Dodatno ispitivanje robusnosti rezultata provedeno je kombiniranjem dva opisana pristupa istraživanju, pri čemu je razmatran individualan utjecaj pojedinih sektora na rast. Riječ je o sektorima financijskih i poslovnih usluga te sektorima visoke dodane vrijednosti, i sektoru poljoprivrede i zastarijele industrijske proizvodnje. Dakako, to su sektori za koje se očekuje da imaju izrazito pozitivan, odnosno, izrazito negativan utjecaj na regionalni rast. Dobivenim modelima potvrđene su treća i četvrta pomoćna hipoteza te je, uz potvrdu prisutnosti konvergencije i relevantnosti utjecaja kontrolnih varijabli na rast, dodatno utvrđen značaj specijalizacije za rast BDP-a *per capita* regija. Osim potvrde konzistentnosti rezultata korištenjem različitih pristupa, time su potvrđene sve četiri pomoćne hipoteze, što daje za pravo utvrditi kako je i glavna hipoteza definitivno potvrđena.

Prva pomoćna hipoteza testirana je modelima baziranim na prvom pristupu istraživanju. To su modeli koji kao zavisnu varijablu koriste rast BDP-a po stanovniku, a jedna od nezavisnih je BDP po stanovniku iz razdoblja $t-1$. Kao dodatne kontrolne varijable korištene su varijable korištene su varijable rast populacije, ljudski kapital, investicije te ulaganje u istraživanje i razvoj, dok je varijabla specijalizacije obuhvaćena Herfindahl- Hirschmanovim indeksom. U modelima je zapažena prisutnost konvergencije te relevantnost, odnosno, pozitivan utjecaj specijalizacije na rast BDP-a *per capita*.

Uvažavajući razlike u razinama specijalizacije varijablom Herfindahl-Hirschmanovim indeksom, i pozitivne predznake uz koeficijent varijable specijalizacije, potvrđen je utjecaj razine specijalizacije na produktivnost regija, čime je potvrđena prva pomoćna hipoteza. Nakon što je osnovnim i dodatnim modelima utvrđena i prisutnost konvergencije i značaj sektorske specijalizacije za ekonomske performanse regija, modeli u tablicama 4 i 5 (Prilozi 1-13, Ispisi iz STATA-e 1-13), dobiveni primjenom prvog pristupa, međusobno su uspoređeni kako bi se ispitala konzistentnost rezultata. Neovisno o tome da li je kao varijabla korišten indeks specijalizacije prema udjelu zaposlenih ili prema bruto dodanoj vrijednosti po sektorima, rezultati ukazuju na snažan pozitivan utjecaj specijalizacije (u apsolutnom smislu) na rast BDP-a po stanovniku regija u Europskoj uniji te prisutnost konvergencije između 2 i 6%. Osim navedenog, potvrđeno je kako odabrane varijable, bazirane na relevantnim teorijskim dostignućima, imaju pozitivan utjecaj na rast.

Testiranje prve pomoćne radne hipoteze kojom se nastojalo ispitati da li specijalizacija regija utječe na produktivnost istih ispitano je i alternativnim pristupom testiranja odnosa sektorske specijalizacije i rasta. Rezultati unatoč nekonzistntnosti u predznacima ukazuju na prisutnost konvergencije i signifikantnost utjecaja sektorske specijalizacije na rast (Prilozi 14-20, Ispisi iz STATA-e 14-20). Dvojakost rezultata nije neuobičajena kod pristupa kojim se ispituje relativna specijalizacija (Ezcura et. al. 2008., Kemeny i Storper, 2012.), međutim, razlike u veličinama koeficijenata za pripadajuće sektore specijalizacije ukazuje na razlike u produktivnosti među njima čime se potvrđuje i prva pomoćna hipoteza.

Na istom tragu ispitano je i koliko su razlike među regijama rezultat produktivnosti među sektorima njihovih specijalizacija što proizlazi iz druge pomoćne hipoteze. Usporedbom modela kojima je parcijalno ispitivan utjecaj relativne specijalizacije u pojedinim sektorima (Prilozi 14-20, Ispisi iz STATA-e 14-20). Odabranih pet sektora specijalizacije u modelima imaju diferencirane predznake stoga se **potvrđuje kako su razlike u produktivnostima regija rezultat razlika u produktivnosti među sektorima. Relativno jak utjecaj na rast imaju sektori tržišnih i javnih usluga te industrija, dok sektor poljoprivrede (s niskom produktivnošću) ima negativan i slab utjecaj na rast. Sektor građevinarstva ima srednje jak utjecaj na rast BDP-a po stanovniku što ukazuje na činjenicu da građevinski sektor prati rezidencijalne i druge građevinske potrebe koje proizlaze iz ukupnog razvoja regija.**

Da bi se dodatno ispitala robusnost prethodno predstavljenih rezultata pristupa se posljednjoj fazi istraživanja kojom se ispituje parcijalni utjecaj odabranih sektora za koje se očekuje da imaju najnižu i najvišu produktivnost (poljoprivreda te financijske i poslovne usluge) što proizlazi iz treće i četvrte pomoćne hipoteze. Pristup ispitivanja treće i četvrte pomoćne hipoteze uključuje odabran sektor specijalizacije regija te pomoćne varijable korištene u prvom pristupu: promjene populacije, investicije, ulaganje u istraživanje i razvoj i ljudski kapital. Ovaj pristup svojevrsna je sinteza prva dva pristupa istraživanju, s tim da umjesto apsolutne specijalizacije razmatra relativnu.

Treća hipoteza inicijalno je uključivala ispitivanje produktivnosti sektora financijskih i poslovnih usluga, ali zbog razine agregiranosti podataka dalje se ispituje utjecaj sektora tržišnih usluga

(eng. *market services,* **NACE sekcije G–N**)[18] na regionalni rast. Prikaz dobivenih modela nalazi se u tablici 8, a detaljan ispis modela nalazi se u prilozima 21-23, ispisi iz STATA-e 21-23.

**Tablica 8: Modeli utjecaj odabranih varijabli na rast BDP-a po stanovniku NUTS II regija Europske unije**

| **Varijable** | **Zavisna varijabla rast log_BDP per capita** | | |
|---|---|---|---|
| | M1 | M2 | M3 |
| | va_eu | em_eu | em_eu |
| | Mle | Re | Mle |
| log_GDP per capita (t-1) | -0.0603435<br>(0.000) | -0.0552659<br>(0.000) | -0.0568501<br>(0.000) |
| Sij_market_services | 0.0145312<br>(0.052) | 0.241043<br>(0.000) | 0.0380376<br>(0.000) |
| gerd | 0.000015<br>(0.003) | | 0.0000127<br>(0.057) |
| log_gfc | 0.0059503<br>(0.007) | 0.0124547<br>(0.000) | 0.0135491<br>(0.000) |
| Population_change | 0.0019125<br>(0.000) | 0.012085<br>(0.002) | |
| High_education | | 0.0005404<br>(0.060) | |
| _constant | 0.5461449<br>(0.000) | 0.4211405<br>(0.000) | 0.4134502<br>(0.000) |
| Razdoblje | 2000-2013 | 2000-2013 | 2000-2013 |
| Ukupan broj opažanja | 1103 | 1169 | 991 |
| Broj regija | 145 | 138 | 138 |
| R2 | | | |
| within | | 0.1741 | |
| Between | | 0.4846 | |
| Overall | | 0.1798 | |
| * U zagradama su vrijednosti t-statistike | | | |

Izvor: EUROSTAT, STATA, izračun autora

[18]Trgovina na malo i veliko, transport, usluge smještaja i ugostiteljstva, IT, financije i osiguranje, poslovanje nekretninama, stručne, znanstvene i tehničke aktivnosti, administrativne i potporne aktivnosti (eng. Wholesale and retail trade; transport; accommodation and food service activities; information and communication, Financial and insurance activities; real estate activities; professional, scientific and technical activities; administrative and support service activities)

Dobiveni modeli ukazuju na prisutnost konvergencije po stopama između 5 i 6%, a utjecaj sektora tržišnih usluga na rast BDP-a po stanovniku je snažan i pozitivan i to pri razini signifikantnosti od 1% za modele M2 i M3. Ostale varijable, u skladu s očekivanjima imaju pozitivan i nešto blaži utjecaj na rast. Iz navedenog proizlazi kako **sektor tržišnih usluga jest sektor visoke dodane vrijednosti pa regije specijalizirane u ovom sektoru ostvaruju više stope rasta u odnosu na ostale, čime se potvrđuje treća pomoćna hipoteza.**

Četvrta pomoćna hipoteza inicijalno je glasila: poljoprivredne regije i regije zastarijele industrijske proizvodnje ostvaruju niže stope rasta, međutim, radi načina agregiranosti podataka nije bilo moguće izolirati regije zastarijele industrijske proizvodnje, stoga je analiza obuhvatila samo sektor poljoprivrede (poljoprivreda, šumarstvo i ribarstvo, **NACE sekcija A**, eng. *agriculture, forestry and fishing*). Rezultati su sumirani u tablici 9, a detaljan prikaz modela nalazi se u prilozima 24-27, ispisi iz STATA-e 24-27.

**Tablica 9: Modeli utjecaj odabranih varijabli na rast BDP-a po stanovniku NUTS II regija Europske unije**

| **Varijable** | **Zavisna varijabla rast log_BDP per capita** | | | |
|---|---|---|---|---|
| | M1 | M2 | M3 | M4 |
| | va_eu | va_eu | em_eu | em_eu |
| | Re sa | Be | Re sa | Mle |
| log_GDP per capita (t-1) | -0.0531776<br>(0.000) | -0.0322547<br>(0.000) | -0.0448402<br>(0.000) | -0.0448402<br>(0.000) |
| Sij_agriculture | -0.0033535<br>(0.013) | -0.0014809<br>(0.084) | -0.0041058<br>(0.000) | -0.0041058<br>(0.000) |
| gerd | 0.000017<br>(0.003) | | | |
| log_gfc | 0.008287<br>(0.001) | | | |
| Population_change | | | 0.0006736<br>(0.001) | 0.0006736<br>(0.001) |
| High_education | | 0.0006828<br>(0.000) | 0.0005694<br>(0.006) | 0.0005694<br>(0.005) |
| _constant | 0.4821255<br>(0.000) | 0.3375856<br>(0.000) | 0.4643016<br>(0.000) | 0.4643016<br>(0.000) |
| Razdoblje<br>Ukupan broj opažanja | 2000-2013<br>1295 | 2000-2013<br>2740 | 2000-2013<br>1828 | 2000-2013<br>1828 |

| | | | | |
|---|---|---|---|---|
| Broj regija | 161 | 220 | 218 | 218 |
| R2 | | | | |
| within | 0.2057 | 0.1511 | 0.1328 | |
| Between | 0.6010 | 0.6445 | 0.3787 | |
| Overall | 0.1928 | 0.1601 | 0.1704 | |
| * U zagradama su vrijednosti t-statistike | | | | |

Izvor: EUROSTAT, STATA, izračun autora

Temeljem dobivenih modela može se utvrditi prisutnost konvergencije među regijama Europske unije između 3 i 5% s time da **specijalizacija regije u sektoru poljoprivrede negativno utječe na njihov rast**. Time se potvrđuje četvrta hipoteza prema kojoj uslijed niske produktivnosti ovog sektora, regije u kojima je sektor poljoprivrede više zastupljen ostvaruju niže stope rasta što usporava konvergenciju. Ostale varijable imaju slab pozitivan utjecaj na rast. Nešto veći utjecaj, pozitivan i relativno blag, nalazi se u modelu M1 u tablici za varijablu investicije (log_gfc) što ukazuje na mogućnost unapređivanja produktivnosti regija kroz pojačanu investicijsku aktivnost, naročito u poljoprivrednom sektoru.

Testiranjem treće i četvrte hipoteze dodatno se utvrđuje robusnost rezultata ostalih pomoćnih hipoteza. Kroz validaciju kontrolnih varijabli investicija, ljudskog kapitala, promjena populacije i ulaganja u istraživanje i razvoj potvrđuje se njihov utjecaj i značaj za gospodarski rast na regionalnoj razini, a kroz relativnu sektorsku specijalizaciju parcijalnim ispitivanjem utjecaja potvrđuje se i značaj specijalizacije. Time je također dodatno utvrđena i potvrđena robusnost rezultata testiranja druge pomoćne hipoteze što je raščlambom na odabrane sektore omogućilo uvid u relevantnost utjecaja produktivnosti sektora na utjecaj specijalizacije na regionalni rast.

***Sintezom iznesenog može se izvesti da je potvrdom i unakrsnim ispitivanjem pomoćnih hipoteza dodatno potvrđena glavna hipoteza, što implicira generalni zaključak kako je sektorska specijalizacija relevantna za realnu konvergenciju regija u Europskoj uniji.***

# 6. ZAKLJUČAK

Intencija ovog rada bila je doprinijeti boljem razumijevanju razvojnog procesa na regionalnoj razini uvažavajući uvriježenu tezu kako će sektorska specijalizacijska struktura u određenim okolnostima doprinijeti postizanju regionalne konvergencije mjerene BDP-om *per capita.*

## 6.1 Sažetak rezultata istraživanja

Kao ishodište istraživanja postavljeno je za cilj ispitati relevantna teorijska dostignuća iz područja regionalne ekonomije, kao i ostale teorijske koncepte koji razmatraju rast i razvojne procese, s naglaskom na determinante razvoja, a posebno specijalizaciju kao potencijalan objašnjavajući čimbenik pri ostvarivanju rasta i konvergencije. Nadalje, potvrda ispravnosti teorijskih postavki ispitana je analizom empirijskih dostignuća na ovom području, a kao autentičan doprinos ovog rada ispitana je prisutnost regionalne konvergencije s obzirom na sektorsku specijalizaciju regija na najrecentnijim podatcima za NUTS II regije svih 28 zemalja članica Europske unije. Opisanim redosljedom predstaviti će se najvažnije spoznaje proizašle iz istraživanja.

Razmatrajući ekonomske teorije koje su obilježile nastanak i razvoj regionalne teorije logičnim se nameće početi od neoklasičnog koncepta rasta. Iako je ovu doktrinu obilježilo istraživanje rasta i neujednačenog razvoja na nacionalnoj razini, principi se jednostavno mogu preslikati na regionalnu i lokalnu razinu, stoga se ovaj teorijski pravac opravdano smatra začetkom teorije regionalnog razvoja. Temelj i ishodište neoklasičnog koncepta je Solowljev model iz 1956. godine razvijen kako bi se objasnile stilizirane činjenice rasta. Prema spomenutom modelu u dugom roku dolazi do konvergencije kako se proizvodni faktori zbog razlika u graničnim prinosima mobiliziraju u prostoru, što naposlijetku dovodi do smanjenja razlika u graničnim prinosima rada i kapitala. Razlike u prinosima s vremenom nestaju, a sukladno tome dolazi do smanjenja nejednakosti. Dugoročni rast u Solowljevom modelu objašnjen je akumulacijom proizvodnih faktora i tehnološkim napretkom koji nije objašnjen modelom, već se pojavljuje kao „mana s neba“.

Upravo na tom ključnom nedostatku ovog modela razvila se skupina endogenih modela rasta čiji je glavni doprinos determiniranje dugoročnog rasta unutar modela. Generatorima razvoja, ljudskom kapitalu, inovacijama, ulaganju u istraživanje i razvoj, ulaganju u znanje i

obrazovanje te prelijevanju znanja i tehnologija daje se zasluga za eliminaciju opadajućih prinosa što dovodi do rasta i konvergencije. Najvažniji predstavnici ovog teorijskog koncepta su Romer (1986., 1990.) Lucas (1988.), Grossman i Helpman (1991.) te Aghion i Howitt (1998.). Teoretičari unutar ovog koncepta sektorsku specijalizaciju smatraju pogodnom razvoju naglašavajući kako doprinosi rastu ukupne ekonomske aktivnosti (Romer, 1986.). Prema nekim predstavnicima ovog koncepta specijalizirane industrije na ograničenom geografskom području pogoduju difuziji znanja (Porter, 1990.) koja omogućava iskorištavanje potencijala ekonomije obujma (Ethier, 1985.), oboje važnih izvora razvoja.

Koncept difuzije znanja u prostoru u literaturi o ekonomskoj geografiji datira iz 1960-ih, a inicijalno se povezuje s Perrouxom (1950.) teorijom polova razvoja kojem Boudeville (1966.) daje prostornu dimenziju. Začetnik teorije polova rasta Perroux (1950.) prostor vidi kao mrežu interakcija prožetih centripetalnim silama. Autor polove rasta povezuje sa odnosom poduzeća i industrija. Propulzivna poduzeća (eng. *propulsive firms*), ona poduzeća relativno veća u odnosu na ostale, generiraju inducirani rast kroz interindustrijske veze dok agregatna proizvodnju raste, a pozitivni učinci u formi znanja i inovacija šire se na okolna područja. Na sličan način, Hirschman (1958.) govori o dvije vrste efekata, odnosno učincima prelijevanja. Autor razlikuje veze prema naprijed (eng. *forward linkages*) i veze prema natrag (eng. *backward linkages*) između poduzeća. Prve uzrokuju kretanje prema lokacijama postojeće aktivnosti što može prouzrokovati učinak talasanja (eng. *backwash effect*) kada polovi rasta privuku toliko aktivnosti da se učinci počinju širiti na okolna područja. Potonje se povezuju s aktivnostima u kojima se proizvode inputi za gospodarsku djelatnost i kreću se prema lokacijama na kojima se nalazi velik broj kupaca. Migracije radnika kreću se u smjeru polova rasta uzrokujući daljnju polarizaciju rasta i ograničavajući rast u drugim područjima (Capello i Nijkamp, 2009.).

Određene društvene i ekonomske okolnosti te neglektiranje potražne strane ekonomije u najzastupljenijim teorijskim pravcima rezultirali su razvojem jednog od popularnijih koncepata koji se bavi regionalnim disparitetima, koncepta izvozne baze. Prema ovom konceptu početni impuls izvozu je dato bogatstvo kojim regija raspolaže, a razvoj je determiniran njenom spremnošću da odgovori na egzogenu izvoznu potražnju (North, 1955.). Specijalizacija unutar ovog koncepta zauzima važno mjesto obzirom da se regije specijaliziraju kao odgovor na izvoznu potražnju koja se smatra generatorom razvoja. Također, smatra se kako nakon dostizanja određenog stupnja razvoja specijalizacija gubi svoj značaj uslijed porasta rezidencijalnih dohodaka, koji generiraju potražnju iz drugih sektora.

Na koncu ovi učinci dovode do disperzije proizvodnje kroz zemlju čime se postiže međuregionalna konvergencija (Dawkins, 2003.).

Unutar izvozno orijentiranih koncepata rasta značajno mjesto zauzima i koncept kumulativne uzročnosti prema kojem ekonomija obujma i rastući prinosi djeluju na aglomeriranje ekonomske aktivnosti u regijama koje se prve industrijaliziraju, a proces rasta dodatno je potaknut procesom kumulativne kružne uzročnosti (Myrdal, 1957.). Kaldor (1970.) u Myrdalovu teoriju uvodi produktivnost te daje prednost specijaliziranim regijama zbog iskorištavanja ekonomije obujma, smatrajući kako regije specijalizirane u industrijskom sektoru imaju veći potencijal za porast produktivnosti koji je izvor rasta. Prema njegovoj tezi razvojni put regija uvjetovan je njihovom sektorskom strukturom. Autor također uvodi distinkciju između produktivnih i manje produktivnih sektora. Proces kumulativne kružne uzročnosti pojavljuje se u obliku produbljavanja razlika, odnosno divergencije, pa manje uspješne regije ne uspijevaju u sustizanju razvijenijih unatoč prednostima nižih nadnica te učincima „širenja“ iz kojeg proizlazi prelijevanje znanja i tehnologija. Ove prednosti nisu dovoljne da se eliminiraju početne razlike i da zaostajuće regije sustignu brzo rastuće regije specijalizirane u produktivnijim sektorima. Divergencija je u ovom konceptu neizbježna i može se samo produbljavati. Razvojni put regije unaprijed je određen što ujedno predstavlja glavnu zamjerku ovog koncepta. Taj nedostatak otklonjen je modelom kojeg su razvili Dixon i Thirlwall (1975.), a konvergencija je omogućena uvođenjem relativne promjene cijena (domaćih i inozemnih), cjenovnom elastičnošću potražnje i svjetskom potražnjom. Iz perspektive ovog rada, najvažniji nedostatak ovog modela je zanemarivanje gospodaarske strukture regija, odnosno specijalizacije. Svi ne-cjenovni čimbenici, pa i sektorska struktura, obuhvaćeni su dohodovnom elastičnošću izvoza, iako određeni autori ukazuju na diferencirane stope elastičnosti za različite industrije u izvoznoj strukturi (Amable i Verspagen, 1995.). Neki autori, primjerice Fiorillo (1997.), pokušali su premostiti navedeni nedostatak tako da su bazirali modele na uzajamnom odnosu specijalizacije i rasta: sektorska specijalizacija determinira rast, a rast uvjetuje sektorsku specijalizaciju. Prema njegovom modelu, ekonomije konvergiraju u stanje srednjoročne ravnoteže u kojem su sektorske strukture i stope rasta konstantne, a rezultat je uvelike određen razvojnom putanjom (eng. *path dependency*). Prema Pasinettiju (1981.) različite stope rasta među industrijama određuju specijalizacijske obrasce, a onda i ukupne stope rasta.

Sličan koncept ponudio je Friedman (1966.) u modelu centar-periferija (eng. *center-periphery*) u kojem uključuje elemente Myrdalove teorije neuravnoteženog regionalnog rasta i

teorije izvozne baze iz koje preuzima mogućnost eksterno induciranog rasta. Također, autor naglašava utjecaj međuregionalnih migracija na konvergenciju. Velika urbana područja, prema ovom modelu, imaju inicijalnu prednost pred konkurencijom za daljnji rast kroz opadajuće troškove. Ovi i ostali čimbenici idu u prilog urbanim aglomeracijama koji predvode u rastu. Ruralna područja su u zamci strukturnog siromaštva, prvenstveno zbog njihove strukturne ovisnosti o razvijenim regijama.

Na sintetizi neoklasičnih i polarizacijskih koncepata rasta razvio se koncept Nove ekonomske geografije. Začetak Nove ekonomske geografije vezuje se uz Krugmanov rad (1991.) u kojem koristi Marshallove (1920.) eksternalije vezane za prelijevanje znanja proizašle iz geografske koncentracije industrije, Myrdalovu (1957.) kumulativnu uzročnost procesa rasta, polarizacijske modele i brojne druge elemente koji do pojave Nove ekonomske geografije nikad nisu bili uspješno intergrirani u modelsku formulaciju. Autorov osnovni model (industrijske) jezgre i (poljoprivredne) periferije na proces kumulativne uzročnosti vezuje Dixit-Stiglitzov (1977.) model monopolističke konkurencije u kojem važno mjesto zauzimaju preferencije potrošača i Samuelson-ov (1954.) model ledenjaka (eng. *iceberg*) prema kojem transportni troškovi „otapaju“ dio proizvoda na putu do potrošača sa geografskom udaljenošću. Glavne implikacije modela su pojava učinka „veličine tržišta“ (eng. *home market effect*) iz kojeg proizlazi da se industrije lociraju u blizini velikih tržišta uslijed čega se smanjuju transportni troškovi i što u konačnici dovodi do aglomeriranja ekonomske aktivnosti. Učinak veličine tržišta iz perspektive sektorske strukture gospodarstva implicira određeni stupanj specijalizacije, tako će regije s većim brojem stanovništva biti neto izvoznici industrijskih proizvoda, dok će manje regije biti neto izvoznici poljoprivrednih dobara. Modelom je predviđeno više potencijalnih ravnotežnih stanja ovisno o vrijednostima ulaznih parametara (Fujita i Thisse, 2009.). Razmještaj ekonomskih aktivnosti u prostoru, prema modelu Krugmana (1991.), rezultat je odnosa sila koje potiču aglomeraciju, odnosno grupiranje ekonomskih aktivnosti na određenom prostoru tzv. centripetalnih sila (efekt veličine tržišta, razvijena tržišta rada, pozitivne ekternalije) i sila koje djeluju u suprotnom smjeru, raspršujući ekonomsku aktivnost u prostoru, tzv. centrifugalnih sila (imobilnost proizvodnih faktora, zemljišne rente, negativne eksternalije). Rezultat djelovanja ovih sila, reflektirati će se na regionalne nejednakosti. U slučaju jačeg djelovanja centripetalnih sila doći će do divergencije, odnosno, u slučaju prevage centrifugalnih sila dolazi do divergencije.

Iz perspektive ovog rada potrebno je posebno istaknuti i neke teorijske koncepte koji neposredno razmatraju utjecaj specijalizacije gospodarstava na rad. Ideja o utjecaju

specijalizacije na produktivnost povezuje se s samim začetcima ekonomije kao znanstvene discipline. Nešto noviji teorijski koncepti, oni koji razmatraju učinke specijalizacije unutar aglomeracijske ekonomije vezuju se za kraj 19. stoljeća. Tradicionalna lokacijska teorija uz prisustvo savršene konkurencije očekuje pojavu trgovine proizvodima različitih industrija, što pogoduje produbljavanju razlika u sektorskim strukturama regija (Capello i Nijkamp, 2009.). Unutar ovog teorijskog pravca čitav niz radova nastao je s namjerom da se objasne značajke aglomeracijske ekonomije s naglaskom na izvore rasta. Na tragu postavki Marshalla (1920.) koji stavlja naglasak na eksternalije proizašle iz prelijevanja znanja te Hoovera (1948.) koji prednosti sažima u ekonomijama obujma proizašlim uz veličine tržišta, ekonomisti tog vremena smatrali su kako će se uslijed trgovine neminovno pojaviti obrasci koncentracije i specijalizacije, a učinci eksternalija proizašlih iz aglomeracije ekonomske aktivnosti u prostoru razlikovati će se međusobno među sektorima (Duranton i Puga, 2000.). Radovi unutar ovog pristupa nalaze nekoliko razloga zahvaljujući kojima se određene industrije lokaliziraju na nekim područjima podupirući rast. Prvo, koncentracija poduzeća nudi tržište radne snage određenih vještina specifičnih za promatranu industriju. Drugo, lokalizirane industrije mogu poduprijeti proizvodnju netrživih (eng. *nontradable*) specijaliziranih inputa. Treće, prelijevanja znanja među umreženim poduzećima unutar iste industrije rezultiraju relativno boljom proizvodnom funkcijom u odnosu na samostalne proizvođače (Krugman, 1991.).

Unutar teorije međunarodne trgovine predstavnici smatraju kako će se regije specijalizirati u proizvodnji onih dobara za koje posjeduju komparativne prednosti dok se radna snaga kreće prema onim idustrijama koje su učinkovitije, bez narušavanja distribucije dohodaka, što u stvarnosti nije slučaj. Na osnovu modela „Rikardijanskog“ tipa nastao je određen broj radova u kojima se ističe kako različite aktivnosti prati diferenciran rast produktivnosti iz čega proizlazi kako će regije s povoljnijom sektorskom strukturom ostvarivati brži rast. Iz toga je proizašla teza kako je u svrhu upravljanja rastom potrebno manipulirati obrascima specijalizacije (Grossman i Helpman, 1991.). Ipak, jednostavna teorija poput ove suočena sa stvarnim obrascima specijalizacije, ostavila je dosta pitanja otvorenim (p.124 Armstrong i Taylor, 2005.).

Određen iskorak postignut je Heckscher-Ohlinovim (HO) faktorsko-proporcionalni model u kojem su u središtu razmatranja kretanja resursa kao izvora dvosmjerno korisne trgovine među zemljama. Prema modelima ove skupine, s obzirom na komparativne prednosti (u predtrgovinskoj fazi), uslijed međusobne trgovine regija, faktorski tijekovi determinirati će

cjenovnu konkurentnost dobara u razmjeni. Slijedom navedenog, zemlja će se specijalizirati u proizvodnji onih dobara kod kojih može postići troškovnu učinkovitost, a konačan rezultat međunarodne trgovine je interindustrijska trgovina i rast diverzifikacije sektorskih struktura. Model je doživio izuzetnu popularnost, a usprkos brojnim preinakama s obzirom na ograničenja, nije postignut značajan doprinos u smislu objašnjenja promatranih činjenica. Dakako, najistaknutiji nedosatatk modela bio je izostanak empirijske potvrde (Sen, 2010.).

Osamdesete godine prošlog stoljeća donijele su novi koncept baziran na potražnoj strani gospodarstva, novu trgovinsku teoriju. Glavni zaokret u odnosu na tradicionalnu teoriju međunarodne trgovine napravljen je uvođenjem rastućih prinosa i davanjem važnosti benefitima ostvarenim kroz međunarodnu trgovinu – Dixit Stiglitzovim modelom (1977.). Unutar ovog teorijskog pristupa neposrednost je instrument pomoću kojeg poduzeća eksploatiraju učinke ekonomije obujma i rasta tržišnog udjela, a zbog diferencijacije proizvoda dolazi do porasta intraindustrijske trgovine, odnosno trgovine proizvoda koji se mogu smatrati bliskim supstitutima (Krugman, 1980.). Rezultat intraindustrijske trgovine je specijalizacija u proizvodnji različitih varijanti istih proizvoda. Uklanjanje trgovinskih barijera, omogućava daljnju eksploataciju ekonomija obujma, međutim, za razliku od neoklasičnih koncepata rasta, ne dolazi do znatnih promjena u sektorskim strukturama (Krugman, 1981.).

Opisani teorijski pravci, međutim, nisu razmatrali utjecaj trgovine na distribuciju dohodaka regija, odnosno na konvergenciju. Određen iskorak po tom pitanju ponudio je Porter (1990.) uvodeći konkurentsku prednost regija, koja s obzirom na trgovinske tijekove djeluje na njenu agregatnu produktivnost. Koristi od trgovine eksploatiraju se tako što će se regija specijalizirati u onim industrijama u kojima postiže veću produktivnost, dok bi proizvode iz sektora u kojima je manje produktivna trebala uvoziti. Na tragu MAR eksternalija, autor zaključuje kako preljevanjima znanja pogoduje okruženje specijalizirane, prostorno ograničene industrije.

Ipak, potrebno je naznačiti kako je među ekonomistima i dalje prisutna debata o tome da li specijalizirano okruženje pogoduje gospodarskom rastu i razvoju. Prednosti iz specijalizacije evidentne su u korištenju ekonomije obujma, pozitivnim učincima koji proizlaze iz difuzije znjanja, sektorski i intersektorski. Međutim, s druge strane postoje i nezanemarivi argumenti koji upozoravaju na opasnosti koje prijete visoko specijaliziranim gospodarstvima, kao što su primjerice izražena osjetljivost na promjene u cijenama, promjene u potražnji, te ostale

šokove vezane uz visoku razinu specijaliziranosti gospodarstava. Dio autora smatra kako restrikcija eksternalija na određenu industriju ignorira važan izvor interindustrijskog preljevanja znanja (Feldman i Audretsch, 1999.). Jacobs (1969.) primjerice smatra da diverzificirana struktura pogoduje rastu i kako različitost industrija ide u prilog eksternalijama, uz prisutnost zajedničke baze koja potiče interakcije među industrijama.

Promatrajući diferencirane teorijske pristupe i njihova dostignuća, ali i ograničenja, jasno je kako je validaciju postavljenih teza potrebno potražiti unutar empirijskog pristupa. Rezultati empirijskih istraživanja konvergencije variraju ovisno o tome koja vrsta konvergencije se razmatra, kojom metodologijom i na kojem području. Baumol (1986.) nalazi da zemlje s inicijalno nižom razinom BDP *per capita* ostvaruju više stope rasta što implicira postojanje procesa konvergencije. U brojnim radovima Barro i Sala-i-Martin (1991., 1992., 1995.) analizirali su konvergenciju regija u različitim zemljama. Pronađeno je postojanje apsolutne konvergencije za regije Sjedinjenih Američkih Država (48 saveznih država), Kanade (10 provincija), Japana (47 prefektura) i uvjetne konvergencije za regije nekih europskih zemalja (73 NUTS II regije). U promatranim zemljama regije su konvergirale po stopi od približno 2% što ukazuje na sporost procesa. Brojne studije kasnije nalaze postojanje uvjetne ili bezuvjetne konvergencije (Durlauf i Quah 1999., de la Fuente, 2000.). Le Gallo i Dall'erba (2005.) u analizu konvergencije uvode produktivnost sektora specijalizacije te nalaze kako je konvergencija usko povezana s produktivnošću sektora specijalizacije. Autori zaključuju da sektor poljoprivrede ostvaruje divergenciju, dok uslužni sektor ostvaruje konvergenciju. Rodrik (2012.) nalazi apsolutnu konvergenciju mjerenu produktivnošću rada u proizvodnji. Istraživanja na području Europske unije daju različite rezulatate ovisno o korištenim podatcima, vremenskim intervalima i primjenjenim statističkim alatima (Combes, Overman, 2003.). Istraživanje vjerojatno najsličnije ovom, rad Cambridge Econometrics (2012) nalazi prisutnost slabe konvergencije i velike razlike u produktivnostima sektora i njihovom utjecaju na rast. Osim navedenih, brojni drugi autori istraživali su proces konvergencije, no ovisno o primjenjenoj metodologiji rezultati su nerijetko u suprotnosti, stoga se može zaključiti kako do danas nije postignut konsenzus na ovu temu, stoga je ovim radom pokušano ponovo ispitati opisane relacije na najaktualnijim dostupnim podatcima.

Slijedom navedenog glavna hipoteza glasi: Realna konvergencija regija Europske unije uvjetovana je njihovom specijalizacijom. Za objašnjenje glavne hipoteze korištene su i četiri pomoćne. Prva pomoćna hipoteza zasniva se na neoklasičnom i endogenom teorijskom konceptu (Solowa, 1956., Swana, 1956., Romera, 1986., 1990., Lucasa, 1988., Grossman i

Helpmana, 1991., te Aghion i Howitta 1998.), a cilj joj je ispitati odnos specijalizacije regija i razinu produktivnosti istih. Spuštanjem razine analize postavljena je druga hipoteza kako bi se utvrdio izvor razlika u produktivnosti regija uslijed razlika u njihovim sektorskim strukturama. Ovaj pristup ima uporište u "Rikardijanskom" pogledu prema kojem je bitno u kojem se sektoru regije specijaliziraju obzirom da različiti sektori imaju različiti potencijal rasta. Razlozi tome mogu se pronaći na potražnoj strani (različita dohodovna elastičnost između različitih aktivnosti), ali i na strani ponude, odnosno, različitim tehnološkim mogućnostima. Stoga je drugoj pomoćnoj hipotezi cilj ispitati da li su razlike u produktivnosti među regijama rezultat razlika u produktivnosti među sektorima njihovih specijalizacija. Detaljnijom razradom druge pomoćne hipoteze proizlašla je potreba ispitivanja parcijalnih utjecaja pojedinih sektora specijalizacije na ekonomski rast regija. Tako se dolazi do treće pomoćne hipoteze kojom se ispituje da li regije specijalizirane za financijske i poslovne usluge te regije specijalizirane u sektorima visoke dodane vrijednosti ostvaruju više stope rasta u odnosu na ostale regije. S druge strane, sektor poljoprivrede je sektor za koji je uobičajeno da ima nižu produktivnost i sukladno tome negativan utjecaj na rast, stoga je ta teza ispitana četvrtom pomoćnom hipotezom. Potonje dvije pomoćne hipoteze imaju uporište u konceptu Nove ekonomske geografije u kojem različite aktivnosti (industrijske i poljoprivredne) generiraju različite učinke na gospodarstvo.

Hipoteze su postavljene na ispitivanje primjenom dva različita pristupa. U oba pristupa korištena je metodologija panel analize rasta prema modelu uvjetne konvergencije. Također u oba pristupa pojavljuje se rast BDP-a *per capita* kao zavisna varijabla, a kao jedna od nezavisnih pojavljuje se BDP *per capita* iz prethodnog razdoblja, što odgovara konceptu beta konvergencije. U prvom pristupu razmatra se opća razina specijalizacije regija mjerena Herfindahl-Hirschmanovim indeksom, a ostale kontrolne varijable su investicije, promjene populacije, ljudski kapital te istraživanje i razvoj, ovisno o modelu. U drugom pristupu također se razmatra konvergencija mjerena BDP-om po stanovniku, a kao kontrolne varijable koriste se indeksi specijalizacije po odabranih pet skupina sektorske specijalizacije.

U svim dobivenim modelima identificirana je prisutnost konvergencije, odnosno, ovisnost gospodarskog rasta o razini BDP-a *per capita* iz prethodnog razdoblja, u skladu s konceptu beta konvergencije. Sektorska struktura regija, i u apsolutnom i u relativnom smislu, pojavljuje se kao statistički signifikantna varijabla sa utjecajem na rast BDP-a po stanovniku regija. Unutar skupine modela dobivenim primjenom prvog pristupa, apsolutna specijalizacija mjerena Herfindahl-Hirschmanovim indeksom ima snažan pozitivan utjecaj na rast

regionalnog BDP-a *per capita.* Primjenom drugog pristupa istraživanju dobiveni su modeli koji obuhvaćaju indekse specijalizacije po svim sektorima. Iako dvojakih predznaka, vrijednosti koeficijenata ukazuju na činjenicu da je za rast relevantna sektorska struktura regija. Pri tom na rast više utječu sektori tržišnih i javnih usluga te industrija, dok je utjecaj poljoprivrede i građevinarstva manje robustan. Razlike u rezultatima ukazuju na činjenicu da je za konvergenciju važniji koncept apsolutne konvergencije od relativne, ali ukupno gledano, i ovim pristupom potvrđena je prisutnost konvergencije. Parcijalnim razmatranjem utjecaja pojedinih sektora, proizašlim iz treće i četvrte hipoteze, također se dobiva rezultat koji ukazuje na značaj varijable kojom je obuhvaćena specijalizacija. Sektor tržišnih usluga ima snažan pozitivan utjecaj na rast, što ukazuje na činjenicu da je to sektor visoke dodane vrijednosti pa regije specijalizirane u ovom sektoru ostvaruju više stope rasta u odnosu na ostale. S druge strane, sektor poljoprivrede ima negativan i manje robustan utjecaj na rast, stoga se zaključuje kako uslijed niske produktivnosti ovog sektora, regije u kojima je sektor poljoprivrede više zastupljen ostvaruju niže stope rasta što usporava konvergenciju.

Opisanim pristupima ispitane su i potvrđene sve četiri pomoćne hipoteze, rezultat je konzistentan, a robusnost rezultata višestruko je testirana unakrsnim ispitivanjem pomoćnih hipoteza na priličnom broju modela. Temeljem provedenog empirijskog istraživanja stoga se može definitivno utvrditi kako je sektorska specijalizacija relevantna za realnu konvergenciju regija u Europskoj uniji, što je ujedno i glavna hipoteza ovog rada. Rezultat je u skladu s komplementarnim istraživanjima, a politička implikacija rezultata istraživanja je potvrda teze kako je, uz određene uvjete i u određenoj mjeri, rastom moguće upravljati - upravljajući obrascima specijalizacije.

## 6.2 Doprinosi i implikacije istraživanja

U metodološkom smislu, doprinos ovog istraživanja razvidan je iz činjenice kako primjena dvaju različitih pristupa rezultira konzistentnim rezultatima. Također, primjena sinteze opisanih pristupa dodatno potvrđuje tu tezu.

Još jedan od doprinosa provedenog istraživanja je potvrda prisutnosti konvergencije na NUTS II razini regija Europske unije na najrecentnijim podatcima. Pored toga, odnos sektorske strukture regija, u apsolutnim i relativnim terminima, pokazao se značajnim za ekonomski rast, a onda i za konvergenciju. Ovo istraživanje stoga se može svrstati u skupinu radova koji

priznaju specijalizarano okruženje kao pogodno za ekonomski prosperitet regija. Određene razlike u rezultatima, kada je u pitanju parcijalan utjecaj pojedinih sektora na gospodarski rast regija, podsjećaju na činjenicu kako je ekonomija društvena znanost te kako je unatoč razvoju empirijske metodologije prilično ambiciozno očekivati da se modelskim pristupom može obuhvatiti čitava kompleksnost procesa razvoja jednog dinamičnog entiteta kakav je regija.

Potrebno je dodatno napomenuti kako se, razmatrajući druge kontrolne varijable korištene u modelima, zapaža pozitivan utjecaj investicija i ljudskog kapitala na rast. U nešto dužem roku, očekuje se i pozitivan utjecaj ulaganja u istraživanje i razvoj te promjene populacije na rast. Iz navedenog proizlazi i pragmatičan doprinos ovog istraživanja te njegova vrijednost u aplikativnom smislu. Dobiveni zaključci impliciraju, ne samo kako je moguće, u određenoj mjeri upravljati razvojnim procesima, već daju odgovor i na pitanje kako to činiti.

## 6.3 Ograničenja provedenog istraživanja i mogućnosti za daljnja istraživanja

Imajući na umu sve rezultate proizašle iz istraživanja, ekonomist, znanstvenik, osjeća se pozvanim ukazati na potencijalnu primjenu istih. Izazovnost trenutka i ekonomska realnost u kojem se nalazi Europska unija, a i Hrvatska kao njen dio, zacijelo pridonose tom dojmu. Ipak, potrebno je ne dati se zavesti prividnom jednostavnošću rezultata i pomisliti kako će svako rješenje i mjera ekonomske politike, u svakom vremenu i kontekstu, rezultirati dostizanjem željenog cilja. Na tom tragu, potrebno je objektivno sagledati ograničenja istraživanja, iz kojih će proizaći perspektive za daljnji rad u svrhu unapređivanja spoznajnih i aplikativnih dostignuća.

Primarno ograničenje ovog, kao i svakog srodnog istraživanja, ono je tehničke prirode. Raspoloživost kvalitetnih podataka na željenoj razini agregiranosti, kao i dostupnost dovoljno dugih vremenskih serija, zasigurno je jedan od najvećih izazova s kojima se istraživač susreće. No čak i unatoč tome, unutar zone raspoloživosti nadzire se polje nesagledivih mogućnosti za daljnjim radom.

Već na početku samog rada, odabirući razinu analize, pokazatelje razvoja i njegove determinante, pa čak i razinu definicije regija, sukladno ciljevima i svrsi istraživanja, istraživač je svjestan da djeluje u zoni ograničenog, sve ono izvan te zone također otvara prostor s mogućnostima za daljnji istraživački rad. Tu se posebno ističe mogućnost

uključivanja prostorne, a naročito institucionalne komponente, koja je s obzirom na strukturu Europske unije potencijalno jedan od izazovnijih fenomena unutar ovog područja istraživanja.

Razmišljajući o konkretizaciji i primjeni rezultata istraživanja, potrebno je sagledati odabranu razinu analize, pri čemu je razvidna potreba za spuštanjem iste na nešto detaljniji nivo ukoliko se želi efikasnije govoriti o konkretnim smjernicama za nosioce ekonomskih politika te kako bi se dobio metodološki okvir pogodniji za primjenu pri kreiranju konkretnih politika, instrumenata i mjera ekonomske politike, kao i za korištenje u prognostičke svrhe.

## POPIS LITERATURE


1. Aghion, P., Howitt, P. (1998): Endogenous Growth Theory, MIT Press, Cambridge MA.
2. Aghion, P., Howitt, P. (2009): The Econommics of Growth, The MIT Press Cambridge, Massachusetts London, England
3. Amable, B., Verspagen, B. (1995): The Role of Tecnology in Market Share Dynamics, Applied Economics, 27, 197-204.
4. Amiti, M. (1999): Specialization patterns in Europe, Weltwirtschaftliches Archiv, 135, 1-21
5. Arbia, G., Piras, G. (2005): Convergence in per-capita GDP across European regions using panel data models extended to spatial autocorrelation effects, Istituto di Studi e Analisi Economica
6. Armstrong, H., Taylor, J.(2005): Regional Economics and Policy, Blackwell Publishing.
7. Ascani, A.,Crescenzi, R., Iammarino, S. (2012): Regional Economic Development. A Review, SEARCH WP01/03, 2-26.
8. Bachtler, J., Mendez, C., Vironen, H. (2014): Regional development and policy in Europe Contributions for the debate in Latin America, Collection Studies, 2.
9. Baletić, A., et al. (1999): Koncepcija regionalnog gospodarskog razvitka Republike Hrvatske, Ekonomski institut, Zagreb.
10. Barić-Punda, V., Grčić, B., Pečarić, M. (2006): Hrvatska i EU izazovi integracije, Ekonomski fakultet.
11. Barrios Cobos, S. et al. (2000): Multinational enterprises and new trade theory: evidence for the convergence hypothesis. Research paper, Centre for Research on Globalisation and Labour Markets, No. 2000,19.
12. Barro, R.J. (1991): Economic Growth in a Cross Section of Countries, The Quarterly Journal of Economics, 106 (2), 407-443.
13. Barro, R.J., et al. (1991): Convergence Across States and Regions, Brookings Papers on Economic Activity, (1), 107-182.
14. Barro, R.J., Sala-i-Martin, X. (1991): Convergence Across States and Regions, Brooking Papers on Economic Activity, 1, 107-182.
15. Barro, R.J., Sala-i-Martin, X. (1992.): Convergence, Journal of Political Economy 100 (2), 223-251.

16. Barro, R.J., Sala-i-Martin, X. (1995): Economic Growth, New York: McGraw-Hill.
17. Bartkowska, M., Riedl, A. (2012): Regional convergence clubs in Europe: Identification and conditioning factors, Economic Modelling 29, 22-31.
18. Baumol, W. J. (1986): Productivity Growth, Convergence, and Welfare: What the Long-Run Data Show, American Economic Review, 76 (5), 1072-1085.
19. Bernard, A. B., Durlauf, S. N. (1996): Interpreting Tests of the Convergence Hypotesis. Journal of Econometrics, 71 (1-2), 161-173.
20. Bernard, A. B., et al. (2007): Firms in International Trade, NBER Working Paper, No. 13053.
21. Bernard, A., Durlauf, S. (1995.): Convergence in International Output, Journal of Applied Econometrics, (10), 97-108.
22. Bhagwati, J. (1958): Immiserizing Growth: A Geometrical Note, Review of Economic Studies 58: 201–205.
23. Bogunović, A. (1991): Regionalna ekonomika, Narodne novine, Zagreb.
24. Bogunović, A. (2001): Ekonomske integracije i regionalna politika, Mikrorad d.o.o., Zagreb.
25. Borys, M., et al. (2008): Real convergence and the determinants of growth in EU candidate and potential candidate countries: A panel data approach, ECB Occasional paper series 86.
26. Boudeville, J. R. (1966): Problems of regional economic planning. Edinburgh University Press.
27. Brenner, T., Kauermann, G. (2014): Specialization and Convergence of IndustrySpecific Employment in Germany: A Linear MixedModel Approach with Spatial Components, Regional Studies.
28. Brülhart, M., Torstensson, J. (1996): Regional integration, scale economies and industry location in the European Union, CEPR Discussion paper No. 1435.
29. Bulli, S. (2001): Distribution Dynamics and Cross-Country Convergence: A New Approach, Scottish Journal of Political Economy, 48 (2), 226-243.
30. Cambridge Econometrics (2012): Analysis of the main Factors of Regional Growth: An in-depth study of the best and worst performing regions, A final report for the European Commission Directorate General Regional Policy.
31. Canova, F. (2004): Testing for Convergence Clubs in Income per Capita: A Predictive Density Approach, International Economic Review, 44 (1), 49-77.

32. Capello, R., Nijkamp, P. (2009): Handbook of Regional Growth and Development Theories, Edward Elgar Publishing Inc., Massachusetts.
33. Carlino, G., Mills, L. (1993): Are US regional incomes converging? Journal of Monetary Economics, 32 (2), 335-346.
34. Carlino, G., Mills, L. (1996): Convergence and the US States: a Time series Analysis, Journal of Regional Science, 36 (4), 587-616. (b)
35. Carlino, G., Mills, L. (1996): Testing Neoclassical Convergence in Regional Incomes and Earnings, Regional Science and Urban Economics, 26 (6), 564-590. (a)
36. Ciriaci, D. (2004): The Dixon-Thirlwall model and the role of knowledge-based supply specialization: a critical evaluation and suggested extension, GRIF, 1-18.
37. Columbe, S., Lee, F. (1993): Regional economic disparities in Canada, Mimeo (University of Ottawa, Ottawa)
38. Cyrus, T. (2004): Does convergence cause trade, or does trade cause convergence? J. Int. Trade & Economic Development 13:4 397–418
39. Dall'erba, S., Le Gallo, J (2004): Regional Convergence and Structural Funds, 1-40.
40. Dalum, B., et al. (1999): Does Specialization Matter for Growth? Industrial and corporate change, Volume 8, Number 2., Oxford University Press.
41. Davies, S., Hallet, M. (2002): Interactions between National and Regional Development, HWWA Discission Paper 207, str. 1-23.
42. Dawkins, C. (2003): Regional Development Theoty: Conceptual Foundations, Classic Works, and Recent Developments, Journal of Planning Literature, 18 (2), 131-172.
43. De la Fuente, A. (1996): On the sources of Growth and Convergence: A Closer Look at the Spanish Regions, CEPR Discussion Paper No. 1543.
44. De la Fuente, A. (2000): Convergence Across Countries and Regions: Theory and Empirics, CEPR Discussion Paper No. 2465.
45. Dixit, A. K., Stiglitz, J.E. (1977): Monopolistic competition and optimum product diversity, American Economic Review, 67(3), 297-308.
46. Dixon, R. J., Thirlwall, A. P. (1975): A model of regional growth rate differences on Kaldorian lines, Oxford Economic Papers, 27 (2), 201-214.
47. Dumais, G. Et al. (2002): Geographic concentration as a dynamic process, Review of Economics and Statistics
48. Duranton, G., Puga, D. (2000): Diversity and specialisation in cities: why, where and when does it matter?, Urban Studies, 37, 533–55.

49. Durlauf, S. N. (1989): Output persistance, economic structure, and the choice of stabilization policy, Brookings Papers on Economic Activity (2), 69-116.
50. Durlauf, S. N., Quah, D. T. (1999): The New Empirics of Economic Growth, Chapter 4 in Taylor, J. and Woodford, M (Eds.): Handbook of Macroeconomics, Amsterdam: North-Holland.
51. Eckey, H., Kosfeld, R. (2004): New Economic Geography, Working Paper, No. 65, Leibniz Information Centre for Economics, 1-35.
52. Ersoy, A., Taylor, M. (2012): Understanding dynamics of local and regional economic Development in emerging economies, Economic Research, 25 (4), 1079-1088.
53. Evans, P., Karras, G. (1996): Convergence revisited, journal of Monetary Economics, 37 (2), 249-265. (a)
54. Evans, P., Karras, G. (1996): Do Economies Converge? Evidence from a Panel of US States, Review of Economics and Statistics, 78 (3), 384-388. (b)
55. Ezcurra, R., Gil, C., Pascual, P. (2004): Regional Specialisation in the European Union, Universidad Publica de Navarra, 1-39.
56. Fagerberg, J., Verspagen, B. (1996): Heading for Divergence? Regional Growth in Europe reconsidered, Journal of Common Market Studies, 34 (3), 431-448.
57. Farhauer, O., Kröll, A. (2012): Diversified specialisation – going one step beyond the regional economics' specialisation– diversification concept, Jahrbuch für Regionalwissenschaft 32, 63–84
58. Feldman, M. P., Audretsch, D. B. (1999): Innovation in cities: Science-based diversity, specialization and localized competition. European Economic Review 43, 409-429.
59. Fiorillo,F. (1997): Rate of growth and sectoral specialization coevolution in export-led growth model, Quaderni di Ricerca, 95., 3-18.
60. Frenken, K. et al. (2007): Related variety, unrelated variety and regional growth, Regional Studies 41, 685–697.
61. Fujita, M., Krugman, P., Venables, A. (1999): The Spatial Economy; Cities, Regions, and International Trade, The MIT Press, Cambridge, London.
62. Fujita, M., Thisse, F. (2009): New Economic Geography: An appraisal on the occasion of Paul Krugman's 2008 Nobel Prize in Economic Sciences, Regional Science and Urban Economics, 39, 109-119.
63. Fujuta, M., Mori, T. (2005): Frontiers of the New Economic Geography, Blackwell Publishing, Oxford, UK, str. 377-405.

64. Funck, B., Pizzati, L. (2003): European Integration, Regional Policy and Growth, The World Bank, Washington, D.C.
65. Funke, M., Strulik, H. (1999): Regional Growth in West Germany: Convergence or Divergence?, Economic Modelling, 16 (4), 489-502.
66. Galor, O. (1996): Convergence? Inferences from theoretical models. The Economic Journal 106 (437), 1056-1069.
67. Giannone D., Reichlin L. (2006): Trends and business cycles in the euro area: how much heterogeneity and should we worry about it?; Working Paper Series, 595, European Central Bank.
68. Goschin, Z., et al. (2009): Regional Specialization and Geographic Concentration of Industries inRomania. South-Eastern Europe Journal of Economics, 7 (1), 61-76.
69. Grossman, G. M., Helpman, E. (1991): Innovation and Growth in the Global Economy, MIT Press, Cambridge MA.
70. Hadengue, M., Warin, T. (2013): Patterns of Specialization and (Un)conditional Convergence: The Casees of Brazil, China and India, Cirano, 1-29.
71. Hallet, M. (2002). Regional Specialisation and Concentration in the EU., J. R. Cuadrado i M. Parellada (eds.), Regional Convergence in the European Union, Facts, Prospects and Policies. Berlin: Springer-Verlag.
72. Harris, R., (2008): Models of Regional Growth: Past, Present and Future, Centre for Public Policy for Regions, 1-36.
73. Hausmann, R., et al. (2013.): The Atlas of Economic Complexity: Mapping Paths to Prosperity. MIT Press, Cambridge, MA.
74. Hirschman, A. (1958): The strategy for economic development. Yale University Press, New Haven.
75. Hofer, H., Wörgoötter, A. (1997): Regional Per Capita Income Convergence in Austria, Regional Studies, 31 (1), 1-12.
76. Hoover, E.M. (1948): The Location of Economic Activity, New York: McGraw-Hill.
77. Huggins, R., et al. (2014): Regional compettiveness, economic growth and stages..., Zb. Rad. Ekon. Fak. Rij., 32 (2), 255-283.
78. Hulten, C., Schwab, R. (1993): Endogenous growth, public capital, and the convergence of regional manufacturing industries, NBER Working Paper Series, WP 4538.
79. Jacobs, J., 1969. The Economy of Cities. Random House, New York.

80. Johnson, H.G. (1956): International Trade and Economic Growth, Routledge, New York (2013.).
81. Johnson, P. (2000): A Nonparametric Analysis of Income Convergence across the US States, Economic Letters, 69 (2), 219-223.
82. Kaldor, N. (1970): The case for regional policies.. Scottish Journal of Political Economy, 17 (3), 337-348.
83. Kemeny, T., Storper, M. (2012): Specialization and Regional Development, Spatial Economic Research Centre, Discussion Paper 121.
84. Kim, Y., et al. (2000): Industry characteristics linked to establishment concentrations in nonmetropolitan areas, Journal of Regional Science, 40, 231-259.
85. Krueger, D. (2009): Intermediate Macroeconomics, University of Pennsylvania, Philadelphia.
86. Krugman, P (1980): Scale Economics, Product differentiation, and the Pattern of Trade, American Economic Review, 70 (5), 950-959.
87. Krugman, P. (1981): Intraindustry Specialization and the Gains from Trade, Journal of Political Economy 89. 959-973.
88. Krugman, P. (1991): Increasing Returns and Economic Geography, The Journal of Political Economy, 99 (3), 483-489.
89. Krugman, P., Venables, A. J. (1996): Integration, specialization, and adjustment, European Economic Review, 40, 959-967.
90. Kuznets, S. (1955): Economic Growth and Income Inequality, American Economic Review, 45 (1), 1-28.
91. Lall, S., Yilmaz, S. (2000): Regional Economic Convergence: Do Policy Instruments Make a Difference?, Annals of Regional Science, 35 (1), 151-166.
92. Levine, R., Renelt, D. (1992): A Sensitivity Analysis of Cross-Country Growth Regressions, The American Economic Review, Volume 82, Issue 4, 942-963.
93. Lilien, D. M. (1982): Sectoral Shifts and Cyclical Unemployment. Journal of Poltical Economy, 90 (4). 777-793.
94. Loesch, A. (1954): The Economics of Location. Yale University Press, New Haven.
95. Loewy, M. B., Papell, D. H. (1996): Are U.S. Regional Incomes Converging? Some Further Evidence. Journal of Monetary Economics, 38 (3), 587-598.
96. Lucas, R. E. (1988): On the Mechanics of Economic Development, Journal of Monetary Economics, 22 (1), 1-42.

97. Magrini, S. (1999): The evolution of Income Disparities among the Regions of the European Union, Regional Science and Urban Economics, 29 (2), 257-281.
98. Magrini, S. (2003): Regional (Di)Convergence, Handbook of Regional and Urban Economics, 4, 1-77.
99. Magrini, S. (2007): Analysing Convergence throught the Distribution Dynamics Approach: Why and How?, Working Paper, No. 13, Social Science Research Network, 1-39.
100. Mankiw, N. G., et al. (1992): A contribution to the empirics of economic growth, Quaterly Journal of Economics, 107 (2), 407-437.
101. Marelli, E. (2007): Specialisation and Convergence of European Regions, The European Journal of Comparative Economics, 4 (2), 149-178.
102. Marshall, A. (1920): Principles of Economics, MacMillan, London.
103. Martin, R. (1999): The new „geographical turn“ in economics: some critical reflections, Cambridge Journal of Economics.
104. Martin, R. (2001): EMU versus the Regions? Regional Convergence and Divergence in Euroland, Journal of Economic Geography, 1 (1) 51-80.
105. Mervar, A. (1999): Pregled modela i metoda istraživanja gospodarskog rasta, Privredna kretanja i ekonomska politika, 73, 20-61.
106. Midelfart-Knarvik, K. H., et al. (2000): The Location of European Industry. Economic Papers, 142.
107. Molle, W. (1996): The regional economic structure of the European Union: an analysis of long term developments. In K. Peschel (ed.): Regional Growth and Regional Policy Within the Framework of European Integration. Heidelberg: Physica-Verlag.
108. Monfort, P. (2008): Convergence of EU regions Measures and evolutution, Working Papers, 1, European Union Regional Policy, 3-20.
109. Myrdal, G. (1957): Economic Theory and Underdeveloped Regions, London: Duckworth.
110. Niebuhr, A. (2001): Convergence and the Effect of Spatial Interaction, Jahrbuch für Regionalwissenschaft, 21(2), 113-133.
111. Nijkamp, F. (2000): Handbook of Regional and Urban Economics, Elsevier North Holland, Amsterdam.
112. North, D. C. (1955): Location theory and regional economic growth, Journal of Political Economy, 63 (3), 243-258.

113. OECD (1999): EMU: Facts, challenges and policies.

114. O'Hara, P.A. (2009): The principle of circular and cumulative causation; Myrdal, Kaldor and contemporary heterodox political economy, Routledge, 91-105.

115. Osmanković, J. (2002): Teorija i politika regionalnog razvoja Bosne i Hrecegovine, Ekonomski fakultet Univerziteta, Sarajevo.

116. Ottaviano, G., Puga, D. (1998): Agglomeration in the Global Economy: A Survey of the „New Economic Geography“, Blackwell Publishers, 707-730.

117. Öz, Ö. (2000): Assessing Porter's framework for national advantage: the case of Turkey. Journal of Business Research, 55, 509-515.

118. Parker, J. (2002.): Empirical Evidence on Economic Growth, Economics 314 Coursebook, Chapter 6, 2-52.

119. Pasinetti, L. L. (1981): Structural Change and Economic Growth, Cambridge University Press, Cambridge.

120. Perroux, F. (1950): . Economic space: Theory and applications. Quaterly journal of Economics 64 (1), 89-104

121. Porter, M. E. (1990): The Competitive Advantage of Nations, Harvard Business Review, 90211, str. 73-91

122. Portnov, B., Felsenstein, D. (2010): On the sustainability of income inequality measures for regional analysy: Some evidence from simulation analysis and bootstrapping tests, Socio-Economic Planing Sciences 44, 212-219.

123. Puga, D. (1999): The rise and fall of regional inequalities, European Economic Review 43, str. 303-334.

124. Quah, D. (1992): International patterns of growth: Persistance in cross-countrydisparities, Working paper, LSE, London.

125. Quah, D. (1993): Empirical Cross-section Dynamics in Economic Growth, European Economic Review, 37 (2-3), 426-434. (a)

126. Quah, D. (1993): Galton's Fallacy and Tests of the Convergance Hypotesis, Scandinavian Journalof Economics, 95 (4), 427-443. (b)

127. Quah, D. (1994): One Business Cycle and One Trend from (Many,) Many Disaggregates. European Economic Review, 38 (3-4), 605-13.

128. Quah, D. (1996): Convergence Empirics Across Economies with (Some) Capital Mobility, Journal of Economic Growth 1 (1), 95-124. (a)

129. Quah, D. (1996): Empirics for economic growth and convergence, European Economic Review 40, 1353-1375. (b)

130. Quah, D. (1996): Twin Peaks: Growth and Convergence in Models of Distribution Dynamics, Discussion Paper No. 280. (c)

131. Quah, D. (1997): Empirics for Growth and Distribution: Stratification, Polarization, and Convergence Clubs, Journals of Economic Growth, 2 (1), 27-59. (a)

132. Quah, D. (1997): Regional Cohesion from Local Isolated Actions: I. Historical Outcomes, CEP Discussion Paper No. 378, London: CEP. (b)

133. Reggiani, A. (2000): Spatial Economic Science: new Frontiers in Theory and methology, Springer, Berlin.

134. Rivera, M., Romer, P (1990): Economic Integrationa and endogenous Growth, National Bureau of Economic Research, Working Paper, No. 3528, 1-34.

135. Rodrik, D. (2012): Unconditional Convergence in Manufacturing, The Quatrly Journal of Economics, 165-214

136. Romer, P. (1987): Growth Based on Increasing Returns Due to Specialization, Working Paper No. 70.

137. Romer, P. (1993): Idea gaps and objects gaps in economic development, Journal of Monetary Economics, 32, 543-573.

138. Romer, P. (1994): The Origin of Endogenous Growth, The Journal of Economic Perspectives, 8 (1), 3-22.

139. Sala-i-Martin, X. (1994): Regional Cohesion: Evidence and Theories of Regional Growth and Convergence, Journal of Economic Literature, Economic Working Paper (104)

140. Sala-i-Martin, X. (1996): Regional Cohesion: Evidence and Theories of Regional Growth and Convergence, European Economic Review, 40 (6), 1325-1352.

141. Schmutzler, A. (1999.): The new economic geography, Journal of Economic Surveys, 13 (4), 354-379.

142. Sen, S. (2010): International Trade Theory and Policy: A Review of the Literature, The Levy Economics Institute Working Paper No. 635.

143. Shioji, E. (1992): Regional Growth in Japan, Mimeo, (Yale University, New Haven, CT)

144. Sondermann, D. (2012): Productivity in the Euro Area: Any Evidence of Convergence? ECB Working Papers 1431.

145. Stimson, R. et al.(2006): Regional Economic Development: Analysis and Planing Strategy, Springer Science & Business Media, Berlin.

146. Storper, M. (2013): Keys to the City. Princeton University Press, Princeton, NJ.

147. Storper, M., et al. (2015): The Rise and Fall of Urban Economies: Lessons from San Francisco and Los Angeles. Stanford University Press, Stanford, CA.

148. Suedekum, J. (2006): Concentration and specialization trends in Germany since re-unification, Regional Studies 40, 861–873.

149. Thirlwall, A. P. (2013): Kaldor's 1970 Regional Growth Model Revisited, Discussion Papers 1311, 1-11.

150. Tomljanovich, M., Vogelsang, T. J. (2001): Are U.S. Regions Converging? Using New Econometric Methods to Examine Old Issues, Empirical Economics, 27 (1), 49-62.

151. Venables, A. J. (1996): Equilibrium locations of vertically linked industries. International Economic Review 37 (2) 341-359.

152. WIFO (1999), 'Specialisation and (geographic) concentration of European manufacturing', background paper for 'The competitiveness of European Industry; the 1999 report', EC Enterprise Directorate-General, working paper no 1, Brussels.

153. Wood, A., Ridao-Cano, C. (1999): Skill, trade, and international inequality. Oxford Economic Papers 51(1), 89-119.

154. Young, A. (1991): Learning by doing and the dynamic effects of international trade. Quarterly Journal of Economics 106, 369 – 405.

155. Young, A. T., et al. (2008): Sigma Convergence versus Beta Convergence: Evidence from U.S. County-Level Data, Journal of Money, Credit and Banking, vol. 40., 1083-1093.

156. Zhang, J. (2006): International trade, convergence and integration. Eighth Meeting of the European Trade Study Group, Vienna

## PRILOZI:

**Prilog 1.** Ispis iz STATA-e 1

```
. xtreg diferencija pomak  hhi em populationchange loggfc, re

Random-effects GLS regression                   Number of obs      =      1457
Group variable: id_regija                       Number of groups   =       160

R-sq:  within  = 0.2262                         Obs per group: min =         2
       between = 0.4321                                        avg =       9.1
       overall = 0.1890                                        max =        13

                                                Wald chi2(4)       =    295.33
corr(u_i, X)   = 0 (assumed)                    Prob > chi2        =    0.0000

------------------------------------------------------------------------------
 diferencija |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
       pomak |  -.0538285   .0034165   -15.76   0.000    -.0605246   -.0471323
      hhi_em |   .0808624   .0190144     4.25   0.000     .0435948      .11813
population~e |   .0014905   .0003278     4.55   0.000      .000848    .0021331
      loggfc |   .0143693   .0025236     5.69   0.000     .0094231    .0193154
       _cons |   .4139174   .0275562    15.02   0.000     .3599082    .4679267
-------------+----------------------------------------------------------------
     sigma_u |   .0096454
     sigma_e |  .05117846
```

```
         rho |  .03430109   (fraction of variance due to u_i)
------------------------------------------------------------------------------
```

**Prilog 2.** Ispis iz STATA-e 2

```
. xtreg diferencija pomak  hhi em populationchange loggfc  gerd, re sa

Random-effects GLS regression                   Number of obs      =      1233
Group variable: id_regija                       Number of groups   =       160

R-sq:  within  = 0.2211                         Obs per group: min =         2
       between = 0.4753                                        avg =       7.7
       overall = 0.2062                                        max =        12

                                                Wald chi2(5)       =    277.23
corr(u_i, X)   = 0 (assumed)                    Prob > chi2        =    0.0000

------------------------------------------------------------------------------
 diferencija |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
       pomak |  -.0618732   .0041876   -14.78   0.000    -.0700808   -.0536656
      hhi_em |    .060505   .0222638     2.72   0.007     .0168687    .1041412
population~e |    .001941    .000389     4.99   0.000     .0011785    .0027035
      loggfc |   .0140932   .0029695     4.75   0.000     .0082731    .0199133
        gerd |   .0000114   6.52e-06     1.75   0.080    -1.36e-06    .0000242
       _cons |   .4905792   .0372864    13.16   0.000     .4174991    .5636592
-------------+----------------------------------------------------------------
     sigma_u |  .01122921
     sigma_e |  .05323563
         rho |  .04259787   (fraction of variance due to u_i)
```

**Prilog 3.** Ispis iz STATA-e 3

```
. xtreg diferencija pomak  hhi_em loggfc   higheducation, be wls

Between regression (regression on group means)  Number of obs      =      1433
Group variable: id_regija                       Number of groups   =       160

R-sq:  within  = 0.1727                         Obs per group: min =         2
       between = 0.6066                                        avg =       9.0
       overall = 0.1686                                        max =        13

                                                F(4,155)           =     59.75
sd(u_i + avg(e_i.))=  .0195072                  Prob > F           =    0.0000

------------------------------------------------------------------------------
 diferencija |      Coef.   Std. Err.      t    P>|t|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
       pomak |  -.0340031    .002726   -12.47   0.000    -.0393879   -.0286182
      hhi_em |   .0580235   .0154555     3.75   0.000     .0274929    .0885541
      loggfc |   .0043247   .0021007     2.06   0.041     .0001749    .0084744
higheducat~n |   .0004939   .0002465     2.00   0.047     6.93e-06    .0009809
       _cons |   .3071774   .0220705    13.92   0.000     .2635797    .3507752
------------------------------------------------------------------------------

.
```

**Prilog 4.** Ispis iz STATA-e 4

```
. xtreg diferencija pomak  hhi em loggfc populationchange, mle

Fitting constant-only model:

Iteration 0:   log likelihood =   1761.911

Iteration 1:   log likelihood =  1777.9173

Iteration 2:   log likelihood =  1778.5921

Iteration 3:   log likelihood =  1778.5939


Fitting full model:

Iteration 0:   log likelihood =  1931.6326

Iteration 1:   log likelihood =  1931.6369


Random-effects ML regression                    Number of obs      =      1457
Group variable: id_regija                       Number of groups   =       160

Random effects u_i ~ Gaussian                   Obs per group: min =         2
                                                               avg =       9.1
                                                               max =        13

                                                LR chi2(4)         =    306.09
Log likelihood  =  1931.6369                    Prob > chi2        =    0.0000

------------------------------------------------------------------------------
 diferencija |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
```

```
       pomak |  -.0490285   .0030093   -16.29   0.000    -.0549265   -.0431304
      hhi_em |   .0791121   .0163491     4.84   0.000     .0470684    .1111558
      loggfc |   .0121665   .0021949     5.54   0.000     .0078646    .0164683
population~e |   .0012577   .0003032     4.15   0.000     .0006634     .001852
       _cons |   .3879748   .0245818    15.78   0.000     .3397954    .4361541
-------------+----------------------------------------------------------------
    /sigma_u |          0    .006269                           .           .
    /sigma_e |   .0642675   .0011905                      .0619759    .0666437
         rho |  (omitted)
------------------------------------------------------------------------------
Likelihood-ratio test of sigma_u=0: chibar2(01)=    0.00 Prob>=chibar2 = 1.000
```

**Prilog 5.** Ispis iz STATA-e 5

```
. xtreg diferencija pomak  hhi em loggfc populationchange, noconstant mle

Iteration 0:   log likelihood =  1822.4941
Iteration 1:   log likelihood =  1825.5813
Iteration 2:   log likelihood =   1825.693
Iteration 3:   log likelihood =  1825.6934

Random-effects ML regression                    Number of obs      =      1457
Group variable: id_regija                       Number of groups   =       160

Random effects u_i ~ Gaussian                   Obs per group: min =         2
                                                               avg =       9.1
                                                               max =        13

                                                Wald chi2(4)       =    313.35
Log likelihood  =  1825.6934                    Prob > chi2        =    0.0000

------------------------------------------------------------------------------
 diferencija |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
       pomak |  -.0207413   .0036549    -5.67   0.000    -.0279048   -.0135778
      hhi_em |   .1413362   .0241007     5.86   0.000     .0940997    .1885728
      loggfc |   .0241053   .0037714     6.39   0.000     .0167134    .0314972
population~e |  -.0010339   .0003515    -2.94   0.003    -.0017229   -.0003449
-------------+----------------------------------------------------------------
    /sigma_u |   .0203501   .0035557                      .014449    .0286613
```

```
    /sigma_e |   .0669201   .0013666                      .0642944     .069653
         rho |   .0846468   .0282559                      .0416826    .1544653
------------------------------------------------------------------------------
Likelihood-ratio test of sigma_u=0: chibar2(01)=   18.07 Prob>=chibar2 = 0.000


.
```

**Prilog 6.** Ispis iz STATA-e 6

```
. xtreg diferencija pomak  hhi_em loggfc gerd, noconstant mle

Iteration 0:   log likelihood =  1505.6264

Iteration 1:   log likelihood =  1506.6174

Iteration 2:   log likelihood =  1506.6273

Iteration 3:   log likelihood =  1506.6273


Random-effects ML regression                    Number of obs      =      1233

Group variable: id_regija                       Number of groups   =       160


Random effects u_i ~ Gaussian                   Obs per group: min =         2

                                                               avg =       7.7

                                                               max =        12


                                                Wald chi2(4)       =    354.80

Log likelihood  =  1506.6273                    Prob > chi2        =    0.0000


------------------------------------------------------------------------------

 diferencija |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]

-------------+----------------------------------------------------------------

       pomak |  -.0210918   .0033065    -6.38   0.000    -.0275725   -.0146111

      hhi_em |   .1624519   .0227554     7.14   0.000     .1178522    .2070517

      loggfc |   .0253212   .0034669     7.30   0.000     .0185262    .0321161

        gerd |  -.0000383   5.59e-06    -6.86   0.000    -.0000493   -.0000274

-------------+----------------------------------------------------------------

    /sigma_u |   .0163891   .0037032                      .010525    .0255206
```

```
    /sigma_e |   .0697347   .0015243                      .0668102    .0727871
         rho |   .0523438   .0231709                      .0203235    .1154647
------------------------------------------------------------------------------
Likelihood-ratio test of sigma_u=0: chibar2(01)=    7.89 Prob>=chibar2 = 0.002


.
```

**Prilog 7.** Ispis iz STATA-e 7

```
. xtreg diferencija pomak  hhi va loggfc gerd  populationchange, re

Random-effects GLS regression                   Number of obs      =      1295
Group variable: id_regija                       Number of groups   =       161

R-sq:  within  = 0.2287                         Obs per group: min =         2
       between = 0.5913                                        avg =       8.0
       overall = 0.2142                                        max =        12

                                                Wald chi2(5)       =    351.35
corr(u_i, X)   = 0 (assumed)                    Prob > chi2        =    0.0000

------------------------------------------------------------------------------
 diferencija |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
       pomak |  -.0620471   .0038765   -16.01   0.000    -.0696449   -.0544492
      hhi_va |   .0738867   .0192775     3.83   0.000     .0361034    .1116699
      loggfc |   .0093983   .0023648     3.97   0.000     .0047634    .0140332
        gerd |    .000015   5.60e-06     2.68   0.007     4.04e-06     .000026
population~e |   .0017536   .0003471     5.05   0.000     .0010733    .0024338
       _cons |   .5244054   .0311969    16.81   0.000     .4632606    .5855502
-------------+----------------------------------------------------------------
     sigma_u |          0
     sigma_e |  .05232273
         rho |          0   (fraction of variance due to u_i)
```

**Prilog 8.** Ispis iz STATA-e 8

```
. xtreg diferencija pomak  hhi va gerd populationchange loggfc, re

Random-effects GLS regression                   Number of obs      =      1295
Group variable: id_regija                       Number of groups   =       161

R-sq:  within  = 0.2287                         Obs per group: min =         2
       between = 0.5913                                        avg =       8.0
       overall = 0.2142                                        max =        12

                                                Wald chi2(5)       =    351.35
corr(u_i, X)   = 0 (assumed)                    Prob > chi2        =    0.0000

------------------------------------------------------------------------------
 diferencija |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
       pomak |  -.0620471   .0038765   -16.01   0.000    -.0696449   -.0544492
      hhi_va |   .0738867   .0192775     3.83   0.000     .0361034    .1116699
        gerd |    .000015   5.60e-06     2.68   0.007     4.04e-06     .000026
population~e |   .0017536   .0003471     5.05   0.000     .0010733    .0024338
      loggfc |   .0093983   .0023648     3.97   0.000     .0047634    .0140332
       _cons |   .5244054   .0311969    16.81   0.000     .4632606    .5855502
-------------+----------------------------------------------------------------
     sigma_u |          0
     sigma_e |  .05232273
         rho |          0   (fraction of variance due to u_i)
```

**Prilog 9.** Ispis iz STATA-e 9

```
. xtreg diferencija pomak  hhi va gerd populationchange loggfc, re sa

Random-effects GLS regression                   Number of obs      =      1295
Group variable: id_regija                       Number of groups   =       161

R-sq:  within  = 0.2303                         Obs per group: min =         2
       between = 0.5869                                        avg =       8.0
       overall = 0.2142                                        max =        12

                                                Wald chi2(5)       =    339.82
corr(u_i, X)   = 0 (assumed)                    Prob > chi2        =    0.0000

------------------------------------------------------------------------------
 diferencija |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
       pomak |  -.0635314   .0039979   -15.89   0.000    -.0713671   -.0556957
      hhi_va |   .0753232   .0201661     3.74   0.000     .0357984     .114848
        gerd |   .0000154   5.75e-06     2.68   0.007     4.14e-06    .0000267
population~e |   .0018171   .0003556     5.11   0.000     .0011202     .002514
      loggfc |   .0099688   .0024576     4.06   0.000     .0051519    .0147856
       _cons |   .5330416   .0321236    16.59   0.000     .4700805    .5960027
-------------+----------------------------------------------------------------
     sigma_u |  .00515099
     sigma_e |  .05232273
         rho |   .0095987   (fraction of variance due to u_i)
```

**Prilog 10.** Ispis iz STATA-e 10

```
. xtreg diferencija pomak  hhi va gerd populationchange loggfc, mle

Fitting constant-only model:

Iteration 0:   log likelihood =  1506.3203

Iteration 1:   log likelihood =  1524.9495

Iteration 2:   log likelihood =  1525.9231

Iteration 3:   log likelihood =   1525.927


Fitting full model:

Iteration 0:   log likelihood =  1681.9951

Iteration 1:   log likelihood =  1682.0021


Random-effects ML regression                    Number of obs      =      1295
Group variable: id_regija                       Number of groups   =       161

Random effects u_i ~ Gaussian                   Obs per group: min =         2
                                                               avg =       8.0
                                                               max =        12

                                                LR chi2(5)         =    312.15
Log likelihood  =  1682.0021                    Prob > chi2        =    0.0000

------------------------------------------------------------------------------
 diferencija |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
```

```
       pomak |  -.0620471   .0038675   -16.04   0.000    -.0696272    -.054467
      hhi_va |   .0738867   .0192326     3.84   0.000     .0361915    .1115818
        gerd |    .000015   5.59e-06     2.69   0.007     4.07e-06     .000026
population~e |   .0017536   .0003463     5.06   0.000     .0010749    .0024322
      loggfc |   .0093983   .0023593     3.98   0.000     .0047742    .0140224
       _cons |   .5244054   .0311241    16.85   0.000     .4634033    .5854076
-------------+----------------------------------------------------------------
    /sigma_u |          0   .0078129                           .           .
    /sigma_e |    .066021   .0012972                      .0635268    .0686132
         rho |  (omitted)
------------------------------------------------------------------------------
Likelihood-ratio test of sigma_u=0: chibar2(01)=    0.00 Prob>=chibar2 = 1.000
--more—
```

**Prilog 11.** Ispis iz STATA-e 11

```
. xtreg diferencija pomak  hhi va  higheducation populationchange loggfc, mle

Fitting constant-only model:

Iteration 0:   log likelihood =  1810.2808

Iteration 1:   log likelihood =   1826.873

Iteration 2:   log likelihood =  1827.5768

Iteration 3:   log likelihood =  1827.5786


Fitting full model:

Iteration 0:   log likelihood =  1986.0393

Iteration 1:   log likelihood =  1986.0453


Random-effects ML regression                    Number of obs      =      1499
Group variable: id_regija                       Number of groups   =       161

Random effects u_i ~ Gaussian                   Obs per group: min =         2
                                                               avg =       9.3
                                                               max =        13

                                                LR chi2(5)         =    316.93
Log likelihood  =  1986.0453                    Prob > chi2        =    0.0000

------------------------------------------------------------------------------
 diferencija |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
```

```
       pomak |   -.055982   .0035125   -15.94   0.000    -.0628665   -.0490976
      hhi_va |   .0603521   .0183082     3.30   0.001     .0244687    .0962354
higheducat~n |   .0006214   .0002491     2.49   0.013     .0001332    .0011096
population~e |   .0016334   .0003191     5.12   0.000      .001008    .0022588
      loggfc |   .0084211   .0021137     3.98   0.000     .0042784    .0125638
       _cons |   .4739583   .0271472    17.46   0.000     .4207508    .5271658
-------------+----------------------------------------------------------------
    /sigma_u |          0   .0114188                           .           .
    /sigma_e |   .0643221   .0011747                      .0620604    .0666662
         rho |  (omitted)
------------------------------------------------------------------------------
Likelihood-ratio test of sigma_u=0: chibar2(01)=    0.00 Prob>=chibar2 = 1.000
--more—
```

**Prilog 12.** Ispis iz STATA-e 12

```
. xtreg diferencija pomak  hhi va  higheducation populationchange, be wls

Between regression (regression on group means)  Number of obs      =      2728
Group variable: id_regija                       Number of groups   =       220

R-sq:  within  = 0.0671                         Obs per group: min =         3
       between = 0.6513                                        avg =      12.4
       overall = 0.1410                                        max =        13

                                                F(4,215)           =    100.41
sd(u_i + avg(e_i.))=  .0141744                  Prob > F           =    0.0000

------------------------------------------------------------------------------
 diferencija |      Coef.   Std. Err.      t    P>|t|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
       pomak |  -.0287951   .0017803   -16.17   0.000    -.0323041   -.0252861
      hhi_va |   .0154679   .0092851     1.67   0.097    -.0028335    .0337693
higheducat~n |   .0007701   .0001418     5.43   0.000     .0004906    .0010496
population~e |  -.0004751   .0002035    -2.33   0.020    -.0008762    -.000074
       _cons |   .2962419   .0164712    17.99   0.000     .2637761    .3287076
------------------------------------------------------------------------------

.
```

**Prilog 13.** Ispis iz STATA-e 13

```
. xtreg diferencija pomak  hhi va  higheducation populationchange loggfc, re sa

Random-effects GLS regression                   Number of obs      =      1499
Group variable: id_regija                       Number of groups   =       161

R-sq:  within  = 0.2397                         Obs per group: min =         2
       between = 0.5837                                        avg =       9.3
       overall = 0.1904                                        max =        13

                                                Wald chi2(5)       =    333.85
corr(u_i, X)   = 0 (assumed)                    Prob > chi2        =    0.0000

------------------------------------------------------------------------------
 diferencija |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
       pomak |  -.0585779   .0037376   -15.67   0.000    -.0659034   -.0512523
      hhi_va |   .0626181   .0196895     3.18   0.001     .0240274    .1012087
higheducat~n |   .0006183   .0002638     2.34   0.019     .0001013    .0011354
population~e |   .0017772   .0003328     5.34   0.000     .0011249    .0024295
      loggfc |   .0095045   .0022624     4.20   0.000     .0050703    .0139387
       _cons |   .4886857   .0287625    16.99   0.000     .4323123     .545059
-------------+----------------------------------------------------------------
     sigma_u |   .0062455
     sigma_e |  .05023178
         rho |  .01522352   (fraction of variance due to u_i)
```

**Prilog 14.** Ispis iz STATA-e 14

```
. xtreg diferencija pomak  agriculture va eu  industry va eu  construction va eu
marketservices va eu publicservices va eu, re sa


Random-effects GLS regression                   Number of obs      =      2333
Group variable: id_regija                       Number of groups   =       182

R-sq:  within  = 0.2482                         Obs per group: min =        10
       between = 0.6620                                        avg =      12.8
       overall = 0.2194                                        max =        13

                                                Wald chi2(6)       =    596.46
corr(u_i, X)   = 0 (assumed)                    Prob > chi2        =    0.0000

------------------------------------------------------------------------------
 diferencija |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
       pomak |  -.0453937   .0023384   -19.41   0.000    -.0499768   -.0408106
agricul~a_eu |  -.0079047   .0011013    -7.18   0.000    -.0100632   -.0057462
industry_v~u |  -.0173409   .0076028    -2.28   0.023    -.0322421   -.0024398
constru~a_eu |   .0070484   .0038672     1.82   0.068    -.0005312     .014628
markets~a_eu |  -.0306356   .0131086    -2.34   0.019     -.056328   -.0049433
publics~a_eu |  -.0323966   .0069834    -4.64   0.000    -.0460838   -.0187094
       _cons |   .5817363   .0436828    13.32   0.000     .4961196     .667353
-------------+----------------------------------------------------------------
     sigma_u |  .00625804
```

```
     sigma_e |  .04551651
         rho |  .01855263   (fraction of variance due to u_i)
------------------------------------------------------------------------------
```

**Prilog 15.** Ispis iz STATA-e 15

```
. xtreg diferencija pomak agriculture va eu industry va eu construction va eu
marketservices va eu publicservices va eu, be

Between regression (regression on group means)  Number of obs      =      2333
Group variable: id_regija                       Number of groups   =       182

R-sq:  within  = 0.1799                         Obs per group: min =        10
       between = 0.6967                                        avg =      12.8
       overall = 0.2098                                        max =        13

                                                F(6,175)           =     67.00
sd(u_i + avg(e_i.))=  .0140873                  Prob > F           =    0.0000

------------------------------------------------------------------------------
 diferencija |      Coef.   Std. Err.      t    P>|t|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
       pomak |  -.0329906   .0023003   -14.34   0.000    -.0375305   -.0284507
agricul~a_eu |  -.0058634   .0010893    -5.38   0.000    -.0080133   -.0037135
industry_v~u |  -.0143385   .0083727    -1.71   0.089    -.0308629    .0021859
constru~a_eu |  -.0077907   .0043262    -1.80   0.073    -.0163289    .0007475
markets~a_eu |  -.0335722   .0142044    -2.36   0.019    -.0616062   -.0055382
publics~a_eu |  -.0343012   .0078238    -4.38   0.000    -.0497423   -.0188602
       _cons |    .475677   .0464574    10.24   0.000     .3839881    .5673659
------------------------------------------------------------------------------
```

**Prilog 16.** Ispis iz STATA-e 16

```
. xtreg diferencija pomak  agriculture va eu  industry va eu  construction va eu
marketservices va eu publicservices va eu, be wls

Between regression (regression on group means)  Number of obs      =      2333
Group variable: id_regija                       Number of groups   =       182

R-sq:  within  = 0.1814                         Obs per group: min =        10
       between = 0.6968                                        avg =      12.8
       overall = 0.2101                                        max =        13

                                                F(6,175)           =     67.04
sd(u_i + avg(e_i.))=  .0141692                  Prob > F           =    0.0000

------------------------------------------------------------------------------
 diferencija |      Coef.   Std. Err.      t    P>|t|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
       pomak |  -.0330466   .0023024   -14.35   0.000    -.0375907   -.0285025
agricul~a_eu |   -.005861   .0010911    -5.37   0.000    -.0080145   -.0037075
industry_v~u |   -.014164   .0083764    -1.69   0.093    -.0306958    .0023678
constru~a_eu |  -.0075794   .0043565    -1.74   0.084    -.0161774    .0010185
markets~a_eu |  -.0333985   .0141984    -2.35   0.020    -.0614207   -.0053763
publics~a_eu |  -.0340966   .0078303    -4.35   0.000    -.0495506   -.0186426
       _cons |   .4753078   .0464721    10.23   0.000     .3835898    .5670257
------------------------------------------------------------------------------
```

**Prilog 17.** Ispis iz STATA-e 17

```
. xtreg diferencija pomak  agriculture va eu  industry va eu  construction va eu
marketservices va eu publicservices va eu, fe

Fixed-effects (within) regression               Number of obs      =      2333
Group variable: id_regija                       Number of groups   =       182

R-sq:  within  = 0.2931                         Obs per group: min =        10
       between = 0.5775                                        avg =      12.8
       overall = 0.1903                                        max =        13

                                                F(6,2145)          =    148.25
corr(u_i, Xb)  = -0.9602                        Prob > F           =    0.0000

------------------------------------------------------------------------------
 diferencija |      Coef.   Std. Err.      t    P>|t|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
       pomak |  -.1509574   .0057336   -26.33   0.000    -.1622014   -.1397135
agricul~a_eu |  -.0047851   .0027474    -1.74   0.082    -.0101729    .0006026
industry_v~u |   .0308987   .0158151     1.95   0.051    -.0001158    .0619131
constru~a_eu |   .0660356   .0063385    10.42   0.000     .0536053    .0784658
markets~a_eu |  -.0581578   .0316026    -1.84   0.066    -.1201327    .0038172
publics~a_eu |  -.0275197   .0112251    -2.45   0.014    -.0495329   -.0055066
       _cons |   1.516943   .0883573    17.17   0.000     1.343668    1.690218
-------------+----------------------------------------------------------------
     sigma_u |  .10114998
```

```
     sigma_e |  .04551651
         rho |  .83160689   (fraction of variance due to u_i)
------------------------------------------------------------------------------
F test that all u_i=0:     F(181, 2145) =     4.33           Prob > F = 0.0000


.
```

**Prilog 18.** Ispis iz STATA-e 18

```
. xtreg diferencija pomak agriculture va eu industry va eu construction va eu
marketservices va eu publicservices va eu, noconstant

>  mle

Iteration 0:   log likelihood =  3552.0813

Iteration 1:   log likelihood =  3555.1967

Iteration 2:   log likelihood =  3555.2908

Iteration 3:   log likelihood =   3555.291


Random-effects ML regression                    Number of obs      =      2333

Group variable: id_regija                       Number of groups   =       182


Random effects u_i ~ Gaussian                   Obs per group: min =        10

                                                               avg =      12.8

                                                               max =        13


                                                Wald chi2(6)       =    770.61

Log likelihood  =   3555.291                    Prob > chi2        =    0.0000


------------------------------------------------------------------------------

 diferencija |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]

-------------+----------------------------------------------------------------

       pomak |  -.0289317   .0024269   -11.92   0.000    -.0336883    -.024175

agricul~a_eu |   .0040475    .000861     4.70   0.000       .00236    .0057349

industry_v~u |   .0686844   .0054177    12.68   0.000      .058066    .0793028

constru~a_eu |   .0401149   .0043363     9.25   0.000     .0316159    .0486139
```

```
markets~a_eu |   .1205456   .0101912    11.83   0.000     .1005711      .14052
publics~a_eu |   .0401477   .0057088     7.03   0.000     .0289586    .0513368
-------------+----------------------------------------------------------------
    /sigma_u |   .0137548   .0019081                      .0104803    .0180524
    /sigma_e |   .0513934    .000801                      .0498473    .0529875
         rho |   .0668418   .0178757                      .0383525    .1094737
------------------------------------------------------------------------------
Likelihood-ratio test of sigma_u=0: chibar2(01)=   29.12 Prob>=chibar2 = 0.000
```

**Prilog 19.** Ispis iz STATA-e 19

```
. xtreg diferencija pomak agriculture va eu industry va eu construction va eu
marketservices va eu publicservices va eu, mle

Fitting constant-only model:

Iteration 0:   log likelihood =  3330.9786

Iteration 1:   log likelihood =  3359.1967

Iteration 2:   log likelihood =  3360.4674

Iteration 3:   log likelihood =  3360.4712


Fitting full model:

Iteration 0:   log likelihood =  3634.3097

Iteration 1:   log likelihood =   3635.223

Iteration 2:   log likelihood =  3635.2454

Iteration 3:   log likelihood =  3635.2455


Random-effects ML regression                    Number of obs      =      2333

Group variable: id_regija                       Number of groups   =       182


Random effects u_i ~ Gaussian                   Obs per group: min =        10

                                                               avg =      12.8

                                                               max =        13


                                                LR chi2(6)         =    549.55

Log likelihood  =  3635.2455                    Prob > chi2        =    0.0000
```

```
------------------------------------------------------------------------------
 diferencija |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
       pomak |  -.0464482   .0030347   -15.31   0.000    -.0523962   -.0405003
agricul~a_eu |  -.0080585   .0011686    -6.90   0.000    -.0103489   -.0057681
industry_v~u |    -.01763   .0078164    -2.26   0.024    -.0329498   -.0023102
constru~a_eu |   .0079892   .0042761     1.87   0.062    -.0003918    .0163702
markets~a_eu |   -.030439   .0134739    -2.26   0.024    -.0568473   -.0040308
publics~a_eu |  -.0322852   .0071565    -4.51   0.000    -.0463118   -.0182586
       _cons |   .5912485   .0478847    12.35   0.000     .4973961    .6851008
-------------+----------------------------------------------------------------
    /sigma_u |   .0084502   .0023999                      .004843     .014744
    /sigma_e |   .0503301   .0007962                     .0487936     .051915
--more—
```

**Prilog 20.** Ispis iz STATA-e 20

```
. xtreg diferencija pomak agriculture em na industry em na construction em na
marketservices em na publicservices em na, noconstant

> mle

Iteration 0:   log likelihood =  2107.4781

Iteration 1:   log likelihood =    2107.49


Random-effects ML regression                    Number of obs      =      1620

Group variable: id_regija                       Number of groups   =       196


Random effects u_i ~ Gaussian                   Obs per group: min =         2

                                                               avg =       8.3

                                                               max =        13


                                                Wald chi2(6)       =    836.59

Log likelihood  =    2107.49                    Prob > chi2        =    0.0000

------------------------------------------------------------------------------
 diferencija |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
       pomak |  -.0220513   .0016888   -13.06   0.000    -.0253614   -.0187413
agricul~m_na |   .0172775   .0028629     6.03   0.000     .0116663    .0228887
industry_e~a |   .0584892   .0056836    10.29   0.000     .0473494    .0696289
constru~m_na |  -.0238603   .0102415    -2.33   0.020    -.0439332   -.0037874
markets~m_na |   .1254868   .0104812    11.97   0.000      .104944    .1460297
publics~m_na |   .0775646   .0090908     8.53   0.000     .0597471    .0953822
```

```
-------------+----------------------------------------------------------------
    /sigma_u |   .0038283          .                             .           .
    /sigma_e |   .0657562   .0011595                      .0635224    .0680686
         rho |   .0033781          .                             .           .
------------------------------------------------------------------------------
Likelihood-ratio test of sigma_u=0: chibar2(01)=    1.02 Prob>=chibar2 = 0.157


.
```

**Prilog 21.** Ispis iz STATA-e 21

```
. xtreg diferencija pomak marketservices_va_eu populationchange gerd loggfc, mle


Fitting constant-only model:

Iteration 0:   log likelihood =  1352.3532

Iteration 1:   log likelihood =  1379.5673

Iteration 2:   log likelihood =  1381.7175

Iteration 3:   log likelihood =  1381.7382


Fitting full model:

Iteration 0:   log likelihood =  1555.4857

Iteration 1:   log likelihood =  1555.4938


Random-effects ML regression                    Number of obs      =      1103

Group variable: id_regija                       Number of groups   =       145


Random effects u_i ~ Gaussian                   Obs per group: min =         2

                                                               avg =       7.6

                                                               max =        12


                                                LR chi2(5)         =    347.51

Log likelihood  =  1555.4938                    Prob > chi2        =    0.0000


------------------------------------------------------------------------------

 diferencija |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]

-------------+----------------------------------------------------------------
```

```
       pomak |  -.0603435   .0035229   -17.13   0.000    -.0672484   -.0534387
markets~a_eu |   .0145312    .007488     1.94   0.052    -.0001451    .0292075
population~e |   .0019125   .0003245     5.89   0.000     .0012764    .0025486
        gerd |    .000015   5.04e-06     2.97   0.003     5.11e-06    .0000249
      loggfc |   .0059503   .0021933     2.71   0.007     .0016516    .0102491
       _cons |   .5461449   .0299182    18.25   0.000     .4875062    .6047836
-------------+----------------------------------------------------------------
    /sigma_u |  (omitted)
    /sigma_e |   .0590614   .0012574                      .0566476     .061578
         rho |  (omitted)
------------------------------------------------------------------------------
Likelihood-ratio test of sigma_u=0: chibar2(01)=    0.00 Prob>=chibar2 = 1.000
--more—
```

**Prilog 22.** Ispis iz STATA-e 22

```
. xtreg diferencija pomak marketservices_em_eu populationchange loggfc
higheducation, re


Random-effects GLS regression                   Number of obs      =      1169
Group variable: id_regija                       Number of groups   =       138

R-sq:  within  = 0.1741                         Obs per group: min =         2
       between = 0.4846                                        avg =       8.5
       overall = 0.1798                                        max =        13

                                                Wald chi2(5)       =    255.02
corr(u_i, X)   = 0 (assumed)                    Prob > chi2        =    0.0000

------------------------------------------------------------------------------
 diferencija |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
       pomak |  -.0552659   .0038809   -14.24   0.000    -.0628723   -.0476596
markets~m_eu |   .0241043   .0058416     4.13   0.000      .012655    .0355536
population~e |   .0012085   .0003981     3.04   0.002     .0004283    .0019887
      loggfc |   .0124547   .0027304     4.56   0.000     .0071032    .0178063
higheducat~n |   .0005404   .0002869     1.88   0.060     -.000022    .0011027
       _cons |   .4211405   .0317051    13.28   0.000     .3589996    .4832814
-------------+----------------------------------------------------------------
     sigma_u |          0
     sigma_e |  .05500657
```

```
         rho |          0   (fraction of variance due to u_i)
------------------------------------------------------------------------------
```

.

**Prilog 23.** Ispis iz STATA-e 23

```
. xtreg diferencija pomak marketservices_em_eu loggfc gerd, mle


Fitting constant-only model:

Iteration 0:   log likelihood =  1068.4427

Iteration 1:   log likelihood =  1080.1512

Iteration 2:   log likelihood =  1080.6745

Iteration 3:   log likelihood =   1080.676


Fitting full model:

Iteration 0:   log likelihood =  1189.3505

Iteration 1:   log likelihood =  1189.3568


Random-effects ML regression                    Number of obs      =       991
Group variable: id_regija                       Number of groups   =       138

Random effects u_i ~ Gaussian                   Obs per group: min =         2
                                                               avg =       7.2
                                                               max =        12

                                                LR chi2(4)         =    217.36
Log likelihood  =  1189.3568                    Prob > chi2        =    0.0000

------------------------------------------------------------------------------
 diferencija |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
```

```
       pomak |  -.0568501   .0040735   -13.96   0.000    -.0648341   -.0488662
markets~m_eu |   .0380376   .0064959     5.86   0.000     .0253058    .0507694
      loggfc |   .0135491   .0030749     4.41   0.000     .0075224    .0195758
        gerd |   .0000127   6.68e-06     1.90   0.057    -3.99e-07    .0000258
       _cons |   .4134502   .0319646    12.93   0.000     .3508007    .4760998
-------------+----------------------------------------------------------------
    /sigma_u |          0   .0046185                           .           .
    /sigma_e |   .0728686   .0016367                      .0697303    .0761482
         rho |  (omitted)
------------------------------------------------------------------------------
Likelihood-ratio test of sigma_u=0: chibar2(01)=    0.00 Prob>=chibar2 = 1.000


--more—
```

**Prilog 24.** Ispis iz STATA-e 24

```
. xtreg diferencija pomak  agriculture_va_eu gerd  loggfc, re sa


Random-effects GLS regression                   Number of obs      =      1295
Group variable: id_regija                       Number of groups   =       161

R-sq:  within  = 0.2057                         Obs per group: min =         2
       between = 0.6010                                        avg =       8.0
       overall = 0.1928                                        max =        12

                                                Wald chi2(4)       =    298.86
corr(u_i, X)   = 0 (assumed)                    Prob > chi2        =    0.0000

------------------------------------------------------------------------------
 diferencija |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
       pomak |  -.0531776   .0037645   -14.13   0.000    -.0605558   -.0457994
agricul~a_eu |  -.0033535   .0013574    -2.47   0.013    -.0060139   -.0006931
        gerd |    .000017   5.80e-06     2.93   0.003     5.62e-06    .0000284
      loggfc |    .008287   .0025106     3.30   0.001     .0033663    .0132077
       _cons |   .4821255   .0359816    13.40   0.000     .4116029     .552648
-------------+----------------------------------------------------------------
     sigma_u |  .00464491
     sigma_e |  .05317197
         rho |  .00757335   (fraction of variance due to u_i)
------------------------------------------------------------------------------
```

**Prilog 25.** Ispis iz STATA-e 25

```
. xtreg diferencija pomak  agriculture_va_eu higheducation, be

Between regression (regression on group means)  Number of obs      =      2740
Group variable: id_regija                       Number of groups   =       220

R-sq:  within  = 0.1511                         Obs per group: min =         7
       between = 0.6445                                        avg =      12.5
       overall = 0.1601                                        max =        13

                                                F(3,216)           =    130.51
sd(u_i + avg(e_i.))=  .0142009                  Prob > F           =    0.0000

------------------------------------------------------------------------------
 diferencija |      Coef.   Std. Err.      t    P>|t|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
       pomak |  -.0322547   .0020228   -15.95   0.000    -.0362417   -.0282678
agricul~a_eu |  -.0014809   .0008542    -1.73   0.084    -.0031644    .0002027
higheducat~n |   .0006828   .0001401     4.87   0.000     .0004067     .000959
       _cons |   .3375856   .0201776    16.73   0.000     .2978155    .3773557
------------------------------------------------------------------------------

.
```

**Prilog 26.** Ispis iz STATA-e 26

```
. xtreg diferencija pomak  agriculture_em_eu higheducation populationchange, re sa


Random-effects GLS regression                   Number of obs      =      1828
Group variable: id_regija                       Number of groups   =       218

R-sq:  within  = 0.1328                         Obs per group: min =         2
       between = 0.3787                                        avg =       8.4
       overall = 0.1704                                        max =        13

                                                Wald chi2(4)       =    374.43
corr(u_i, X)   = 0 (assumed)                    Prob > chi2        =    0.0000

------------------------------------------------------------------------------
 diferencija |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
       pomak |  -.0448402   .0026711   -16.79   0.000    -.0500754   -.0396049
agricul~m_eu |  -.0041058   .0008433    -4.87   0.000    -.0057587   -.0024528
higheducat~n |   .0005694   .0002052     2.77   0.006     .0001672    .0009715
population~e |   .0006736   .0002025     3.33   0.001     .0002768    .0010705
       _cons |   .4643016   .0239139    19.42   0.000     .4174311    .5111721
-------------+----------------------------------------------------------------
     sigma_u |          0
     sigma_e |  .05783714
         rho |          0   (fraction of variance due to u_i)
------------------------------------------------------------------------------
```

**Prilog 27.** Ispis iz STATA-e 27

```
. xtreg diferencija pomak  agriculture_em_eu higheducation populationchange, mle


Fitting constant-only model:

Iteration 0:   log likelihood =  2350.9781

Iteration 1:   log likelihood =  2366.9004

Iteration 2:   log likelihood =  2367.4562

Iteration 3:   log likelihood =  2367.4571


Fitting full model:

Iteration 0:   log likelihood =  2538.1954

Iteration 1:   log likelihood =  2538.1989


Random-effects ML regression                    Number of obs      =      1828
Group variable: id_regija                       Number of groups   =       218

Random effects u_i ~ Gaussian                   Obs per group: min =         2
                                                               avg =       8.4
                                                               max =        13

                                                LR chi2(4)         =    341.48
Log likelihood  =  2538.1989                    Prob > chi2        =    0.0000

------------------------------------------------------------------------------
 diferencija |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
```

```
-------------+----------------------------------------------------------------
       pomak |  -.0448402   .0026674   -16.81   0.000    -.0500682   -.0396121
agricul~m_eu |  -.0041058   .0008422    -4.88   0.000    -.0057564   -.0024551
higheducat~n |   .0005694   .0002049     2.78   0.005     .0001678     .000971
population~e |   .0006736   .0002022     3.33   0.001     .0002773      .00107
       _cons |   .4643016   .0238811    19.44   0.000     .4174955    .5111077
-------------+----------------------------------------------------------------
    /sigma_u |          0    .022824                           .           .
    /sigma_e |   .0603587   .0009982                     .0584336    .0623473
         rho |  (omitted)
------------------------------------------------------------------------------
Likelihood-ratio test of sigma_u=0: chibar2(01)=    0.00 Prob>=chibar2 = 1.000


--more--
```

## POPIS TABLICA

Tablica 1: Realni BDP po stanovniku (relativno u odnosu na svjetski prosjek) ..... 44

Tablica 2: Pokazatelji specijalizacije ..... 74

Tablica 3: Model između jedinica promatranja, Europska unija NUTS II razina, 2000-2013 79

Tablica 4: Modeli utjecaj odabranih varijabli na rast BDP-a po stanovniku NUTS II regija Europske unije ..... 82

Tablica 5: Modeli utjecaj odabranih varijabli na rast BDP-a po stanovniku NUTS II regija Europske unije ..... 83

Tablica 6: Usporedba dobivenih modela ..... 84

Tablica 7: Modeli utjecaj odabranih varijabli na rast BDP-a po stanovniku NUTS II regija Europske unije ..... 86

Tablica 8: Modeli utjecaj odabranih varijabli na rast BDP-a po stanovniku NUTS II regija Europske unije ..... 90

Tablica 9: Modeli utjecaj odabranih varijabli na rast BDP-a po stanovniku NUTS II regija Europske unije ..... 91

## POPIS GRAFIČKIH PRIKAZA

Grafički prikaz 1: Determinante produktivnosti rada ..... 20

Grafički prikaz 2: Williamsonova krivulja..... 25

Grafički prikaz 3: Aglomeracijska ekonomija i kumulativna uzročnost..... 26

Grafički prikaz 4: Kumulativna uzročnost kroz veze prema naprijed i natrag ..... 31

Grafički prikaz 5: Moguća ravnotežna stanja u neoklasičnom modelu ..... 34

Grafički prikaz 6: Bimodalna distribucija dohodaka ..... 44

Grafički prikaz 7: Relativna dinamika dohotka po stanovniku odabranih NUTS regija 1980-1995. ..... 46

Grafički prikaz 8: Relativna dinamika dohotka po stanovniku odabranih NUTS regija 1980-1995. ..... 47

Grafički prikaz 9: Prostorno uvjetovana relativna dinamika dohotka po stanovniku odabranih NUTS regija, 1980. ..... 49

Grafički prikaz 10: Determinante konkurentske prednosti ..... 57