OVISNOST EKONOMSKE RESPONDIBILNOSTI REGIJA EUROPSKE UNIJE O NJIHOVOJ GOSPODARSKOJ STRUKTURI

Ozretić, Vlado

Master's thesis / Diplomski rad

2016

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:124:302191

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**

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

DIPLOMSKI RAD

OVISNOST EKONOMSKE RESPONDIBILNOSTI REGIJA EUROPSKE UNIJE O NJIHOVOJ GOSPODARSKOJ STRUKTURI

Mentor: **Student:**

Doc.dr.sc. Vinko Muštra **Vlado Ozretić, univ.bacc.oecc**

Split, rujan, 2015.

SADRŽAJ

1. **Uvod** 1
   - **1.1.Problem istraživanja** 1
   - **1.2. Predmet istraživanja** 2
   - **1.3. Istraživačka pitanja** 3
   - **1.4. Svrha i ciljevi istraživanja** 4
   - **1.5. Metodologija istraživačkog rada** 4
   - **1.6. Doprinos istraživačkog rada** 5
   - **1.7. Struktura diplomskog rada** 5
2. **Ekonomska respondibilnost** 6
   - **2.1.Prijevod pojma „resilience“** 6
   - **2.2. O ekonomskoj respondibilnosti** 9
   - **2.3.Ekonomska respondibilnost i razina zaposlenosti** 13
     - **2.3.1. Indeks osjetljivosti** 14
3. **Regionalizam u ekonomskom smislu** 15
   - **3.1. Regije kao oblikovatelji ekonomske aktivnosti** 15
   - **3.2. Specijalizacija regija** 17
4. **Empirijski model odnosa ekonomske responibilnosti regija EU i njihove gospodarske strukture** 18
   - **4.1.Prostorna i vremenska definicija uzorka** 18
   - **4.2. Uzorak istraživanja** 19
   - **4.3. Postavke modela** 22
     - **4.3.1. Intenzitet ekonomske respondibilnosti kod NUTS2 regija EU** 23
       - **4.3.1.1. Izračun indeksa osjetljivosti** 23
       - **4.3.1.2. Signifikantnost razlika ekonomske respondibilnosti** 24
     - **4.3.2. Gospodarska struktura regija i njihov gospodarski rast** 25
       - **4.3.2.1.Izračun indeksa specijalizacije** 25
       - **4.3.2.2. Utjecaj gospodarske strukture regije na njezin gospodarski rast** 27
     - **4.3.3. Gospodarska struktura regija i njihova ekonomska respondibilnost** 30
   - **4.4.Rezultati istraživanja** 31

4.4.1. Analiza signifikantnosti razlika ekonomske respondibilnosti 31
4.4.2. Analiza odnosa gospodarske strukture regija EU i njihovog gospodarskog rasta 32
4.4.3. Analiza odnosa gospodarske strukture regija EU i njihove ekonomske respondibilnosti 45
5. Zaključak 47
6. Popis literature 49
7. Popis tablica 52

SAŽETAK

Zadnjih nekoliko godina, naročito od pojave velike recesije 2008. godine u fokusu ekonomskih istraživača, i analitičara našao se pojam „resilience“, odnosno kako se prevodi u ovom radu, respondibilnost. Njime se označava reakcija entiteta, bilo države, bilo regije, ili nečeg trećeg na šokove. Ali ne samo za vrijeme i poslije recesije, već i sklop mjera i politika koje uvjetuju i ex ante reakciju, odnosno definiraju pripremljenost, a sve uzimajući u obzir dinamički aspekt svjetske ekonomije.

U fokusu je zadnjih godina, i regionalna ekonomija. Upravo njome Europska unija cilja na one „nezdrave“, slabije razvijene dijelove, te tako nastoji eliminirati regionalne disparitete.

Biti najbolji u nečemu nekoć je značilo mnogo. Znači i danas, ali ne i na ekonomskom planu. Recesija koja je pogodila svijet prije devet godina potvrdila je ono što su ekonomski analitičari sumnjali - specijalizacija pojedinih regija, što nasljedna, što uvjetovana, uvelike utječe na njihovu reakciju na eksterne šokove, odnosno na njihovu ekonomsku respondibilnost.

Sinergija regionalne ekonomije i ekonomske respondibilnosti pokazala se kao dio duha vremena. Od zadnje recesije pojavilo se nekoliko načina mjerenja osjetljivosti regija, a u radu će fokus biti na jednom od njih i on će nam predstavljati mjeru ekonomske respondibilnosti koja će biti stavljena u odnos sa specijalizacijom regija, odnosno s njihovim indeksom specijalizacije.

Ključne riječi su **regije, gospodarska struktura, specijalizacija, ekonomska respondibilnost.**

ABSTRACT

Over the last couple of years the term, especially after the recession that struck in 2008., the term „resilience“ has found itself in the focuses of many economical analysts. Resilience marks a reaction, whether from a country, region, o an eco-system, to exterior shocks. But not only during and after the shocks, but even in ex ante cases where it summarizes all the policies being made from the regions and governments ion order to prepare for the recession. And in the same time taking the dynamical character of the world economy into aspect.

Also, regional economy has caught the attention of economical analysts. And rightfully so, considering that regional economy is one of the European Union's main „weapons“ against regional disparities.

Being best at something once meant something. Today, it still does. But, not in an economical way of thinking and doing business. At least as regions are concerned. The last recession only confirmed the ideas that have been on analysts minds for some time. That the specialization of regions (whether if it's conditional, inherent, or some other type) has a great impact on the regions economic resilience.

Synergy of economic resilience and regional science is the part the „ zeitgeist“ . Evers since the last recession there has been a increase in designing new ways to measure resilience. In this paper we will focus on one of them, and it will represent a certain resilience value which will be compared with the specialization of regions.

Keywords: **regions, economic structure, specialization, economic resilience**

1. UVOD

1.1. Problem istraživanja

Države diljem svijeta konstantno su izložene raznim vrstama šokova među kojima su najčešće financijske krize, fluktuacije u cijenama roba, te nestabilnosti svjetskih gospodarstava. Sanchez et al. (2015) konstatiraju kako ti šokovi mogu povećati rizike i nesigurnosti kako za domaćinstva tako i za države. A, kada postanu dovoljno veliki i perzistentni potiču krize koje izbacuju gospodarstva s njihove putanje dugoročnog rasta i izazivaju razdoblja stagnacije. Tako se izmjenjuju razdoblja uzleta i razdoblja pada svjetskih gospodarstava, a takvo viđenje stvari uvelike je povezano s Keynesijanskom teorijom o poslovnim ciklusima (Domazlicky, 1980).

Ersoy i Aksel (2012) konstatiraju kako danas, u svjetlu toga što se svjetska ekonomija rapidno mijenja, više nego ikad postoji potreba za razumijevanjem regionalne dimenzije rasta. Zadnjih dvadesetak godina regionalni aspekt razvoja biva sve više u fokusu ne samo ekonomista, već i znanstvenika u ostalim društvenim znanostima. Koliko je prostorna dimenzija zapravo u trendu potvrđuje i činjenica da je Paul Krugman prvenstveno zbog nje dobio i Nobelovu nagradu 1991. godine. Naime, američki je ekonomist prestižnu nagradu zaslužio za svoj doprinos „novoj ekonomskoj geografiji“ u kojem je uobličio ideju povećanih prinosa koji, pak, dovode do aglomeracije i rasta bogatih regija, što posljedično izaziva pojavu divergencije bogatih u odnosnu na siromašne regije.

Propadanja regionalnih ekonomija uzrokovano recesijom iz 2008. godine u kombinaciji s nedavnim trendom povećanog zanimanja za održiv razvoj ponovno je u fokus vratila regije, njihovu ekonomiju, kao i način na koji bi mogle poboljšati svoju samodostatnost, otpornost, održivost.

Fagerberg, Verspagen i Caneils (1997) slažu se kako je zaposlenost jedna od glavnih ekonomskih varijabli prilikom evaluacije ekonomskih performansi regija. Konkretno onih u Europskoj uniji. A, Martin (2012) u svom radu izračunava indeks osjetljivosti (kojeg u ovom radu također zovemo i Martinovim indeksom) koristeći upravo razine zaposlenosti u regiji i državi postavljajući tako pojam respondibilnosti u direktnu vezu s regionalnim i državnim razinama zaposlenosti. Kako se analizira u publikaciji „Territorial Dynamics in Europe:

Economic Crisis and the Resillience of Regions“ [1], dok su neke regije relativno brzo povratile gospodarstvo na razinu jednaku onoj prije nastupanja krize (razina outputa i razina zaposlenosti), druge su, pak, zastale u procesu oporavka što je rezultiralo da je veliki broj regija ušao u razdoblje dugoročne stagnacije. Do 2011. čak dvije trećine regija Europske unije nije se oporavilo i došlo do istih razina zaposlenosti i koje su imali prije krize. Štoviše, polovica tih regija tek je odnedavno prestala padom ekonomskih aktivnosti. S druge strane, desetina regija Europske unije izdržalo je krizu bez značajnijih fluktuacija agregatne ekonomske aktivnosti. Nisu iskusile niti pad zaposlenosti niti pad ekonomskog outputa, te su nastavile s rastom.[2]

Kada analiziramo faktore koji utječu na rast, nalazimo kako regije koje pripadaju određenoj tipologiji bivaju pogođene na različite načine, različitim faktorima rasta i različitim intenzitetima. Samim time sugerira se da se jednakim paketom politika ne može utjecati na sve regije jednako, što u cijelu priču uključuje i njihovu specijalizaciju u određenim djelatnostima. Problem istraživanja ovog rada, stoga, je odnos specijalizacije regija Europske unije i njihove ekonomske respondibilnosti.

1.2. Predmet istraživanja

Iz prethodno definiranog problema istraživanja dolazimo do predmet istraživanja. U radu se teorijski istražuje, te empirijski identificira smjer i kvantificira ovisnost ekonomske respondibilnosti regija Europske unije u o njihovoj gospodarskoj strukturi za koju ćemo, pak, analizirati njeno determiniranje gospodarskog rasta.

Ključne riječi su dakle **regije**, **gospodarska struktura**, **gospodarski rast**, te **ekonomska respondibilnost**.

[1] NAPOMENA: Publikacija se citira kao: Territorial Observation No.12 (2014), „Territorial Dynamics in Europe: Economic Crisis and the Resilience of Regions, a u nastavku rada na nju se odnosi pod imenom Teritorijalno izvješće (2014)

[2] Sličan scenarij primijećen je i u Sjedinjenim Američkim Državama. Grupa autora (2015) u radu „A Framework for Measuring County Economic Resilience“ zabilježila je kako američke regije također bilježe različite stope reagiranja i oporavka od eksternih šokova što pripisuju različitom stupnju ekonomske respondibilnosti istih regija zbog čega su pristupili izradi posebnog indeksa ekonomske respondibilnosti s kojim su mjerili spremnost pojedine regije na eksterne šokove

1. 3. Istraživačka pitanja

Na temelju problema i predmeta istraživanja definirane su sljedeće hipoteze.

GH: Gospodarska struktura regije signifikantno utječe na njenu ekonomsku respondibilnost.

U analizi provedenoj u publikaciji Teritorijalno izvješće (2014) naznačeno je nekoliko faktora koji su pozitivno korelirani s regijama Europske unije koje imaju veću razinu ekonomske respondibilnosti. Ti faktori uključuju diversificirana gospodarstva uglavnom orijentirana na izvoz koja se temelje na inovativnoj i obrazovanoj radnoj snazi. Dakle, pored zaposlenosti, ostali faktori su stupanj diversificiranosti odnosno specijalizacije, količina i intenzitet izvoza, stupanj inovacija i obrazovanosti radne snage.

PH1: Regije Europske unije bilježe signifikantne razlike u intenzitetu ekonomske respondibilnosti

U radu ćemo se baviti i istraživanjem faktora rasta regija, čiji je pad ujedno i indikator ekonomskog oštećenja, a koji tipiziraju regiju u pogledu njene gospodarske strukture. Kako već postoji sustav tipizacija regija po njihovoj gospodarskoj strukturi, onaj u Izvješću (2012), logično je da te regije (npr. turističke regije i poljoprivredne regije) međusobno bilježe razlike između gospodarskih struktura. Samim time, iz predstavljene literature izgledno je kako će i njihov odgovor na različite egzogene šokove biti različiti. To, pak dovodi do pomoćnog istraživačkog pitanja koje pretpostavlja da su razlike u gospodarskoj strukturi, a samim time i u intenzitetu ekonomske respondibilnosti, odnosno u indeksu osjetljivosti[3] (veza između ta dva pojma je i premisa cijelog rada) prisutne i signifikantne.

PH2: Gospodarska struktura regija Europske unije determinira gospodarski rast promatranih regija

Kako se ovdje radi o specijaliziranim regijama, željeli smo utvrditi hoće li, u ovisnosti o njihovoj gospodarskoj strukturi, intenzitet pojava poput zaposlenosti, te gospodarskog rasta varirati. To je upravo i cilj prikazati u radu – pokazati je li specijalizacija regija zapravo

[3] Radi se o veličini predstavljenoj u radovima Martina (2012), te Fingleton et al. (2012), a koja postavlja vrijedan metodološki okvir kojeg često koriste u studijama nako njihovih, a koje se tiču ekonomske respondibilnosti i ne samo razine zaposlenosti već i stopa rasta BDP-a, te BDP-a per capita

statistički značajna , odnosno da li ona determinira gospodarski rast i je li njen odnos s ekonomskom respondibilnošću signifikantan.

1. 4. Svrha i ciljevi istraživanja

Svrha ovog istraživanja jest pružanje uvida u postojanje veze između gospodarske strukture regija EU i njihove ekonomske respondibilnosti, određivanje prirode te veze, te definiranje mehanizama preko kojih sve gospodarska struktura regija može utjecati na njihovo reagiranje na eksterne šokove. U empirijskom dijelu će se ti mehanizmi i kvantificirati u vidu potencijalnog utjecaja kojeg gospodarska struktura regija EU ima na njihovu ekonomsku respondibilnost. Zato je glavni cilj ovog rada pružiti odgovore na pitanja:

1) U kojoj mjeri su dosadašnja pojašnjenja ekonomske respondibilnosti do kraja definirala taj pojam?

2) Je li gospodarska struktura regija Europske unije povezana s gospodarskim rastom, kao i ekonomskom respondibilnošću tih istih regija?

3) Je li utjecaj gospodarska struktura regija Europske unije na njihovu ekonomsku respondibilnost signifikantan.

1. 5. Metodologija istraživanja

Rad se sastoji od teorijskog i empirijskog dijela. Teorijski dio rada temelji se na prikupljanju i analiziranju postojeće znanstvene literature i empirijskih istraživanja. Opće znanstvene metode koje će se koristiti u teorijskom dijelu rada su: metoda analize, metoda sinteze, metoda klasifikacije, metoda kompilacije, metoda deskripcije, te induktivna i deduktivna metoda.

S ciljem dokazivanja postavljenih istraživačkih hipoteza, u empirijskom dijelu rada koristit ćemo se relevantnim statističkim metodama koje će definirati sama priroda podataka koju prikupimo. Kako podaci sadrže prostornu komponentu (eng. cross-sectional data) i vremensku komponentu (eng. time-series analizirali smo ih panel podacima, konkretno AB procjeniteljem u dva koraka. Njime se na adekvatan način može procijeniti utjecaj jedne ili više varijabli na promatranu zavisnu varijablu. Taj postupak urađen je za testiranje druge pomoćne hipoteze kao

i same glavne hipoteze. Za testiranje prve hipoteze koristili smo Koglomorov-Smirnov test, te zatim Kruskal-Wallis test.

1. 6. Doprinos istraživanja

Veliki broj radova koncentrirao se na definiranje pojma ekonomske respondibilnosti koji, unatoč tome, i kako postoji konsenzus između samih autora, još do kraja nije posve definiran, barem ne u ekonomiji. Ovo istraživanje za cilj ima definirati preciznije ekonomsku respondibilnost kroz aspekte gospodarske strukture regija Europske unije time što dovodi ekonomsku respondibilnost u direktnu vezu s gospodarskom strukturom regija.

Rad bi trebao pokazati je li ekonomska struktura, odnosno tipizacija regija po djelatnostima NACE nomenklature ključna da regija minimizira utjecaj negativnih gospodarskih kretanja.

1. 7. Struktura diplomskog rada

Diplomski rad sastoji se od pet cjelina. Prvi dio rada nudi uvid u problem i predmet istraživanja, istraživačka pitanja, svrhu i ciljeve istraživanja, te doprinos istraživanja.

U drugom dijelu rada, koncentriranom na pojmu ekonomske respondibilnosti, objašnjava se taj ekonomski fenomen. Navode se relevantna objašnjenja pojma, njegove dimenzije, kao i mjere i implikacije koje ekonomska respondibilnost ima na ekonomsku politiku i performanse regija Europske unije.

Treći dio rada temelji se na pojmu regija i regionalizmu u ekonomskom smislu. Pojašnjeni su razlozi odabira tipizacije regija s obzirom na faktore rasta. Tako se u okviru tog dijela definira sam pojam, te potom prikazuju dosadašnji trendovi u analiziranju ekonomskih performansi regija.

Četvrti, dio rada je empirijski u kojem se prvo krenulo s prostornom i vremenskom definicijom uzorka. Zatim se osvrnulo na sam uzorak koji je korišten u analizi. Potom su predstavljene postavke modela koje su podijeljene u skladu s analizom, gdje su opisane sve varijable korištene u statističkoj analizi. U postavkama modela se i specificiraju relevantne statističke metode s kojima su podaci analizirani, a čiji karakter ovisi o načinu i vrsti prikupljenih podataka. Četvrti

dio završava usporedbom dobivenih rezultata sa prvotno postavljenim istraživačkim hipotezama što rezultira njihovim prihvaćanjem.

U posljednjem, petom dijelu u obliku zaključka, izvršila se se sinergija teorijskog i empirijskog dijela prilikom čega će se u zaključku predstaviti rezultati analize. Kroz navedene cjeline nastojat će se teorijski predstaviti i empirijski istražiti ovisnost ekonomske respondibilnosti regija Europske unije o njihovoj gospodarskoj strukturi. Na kraju će se izvući zaključci koji bi mogli doprinijeti relevantnoj literaturi o utjecaju gospodarske strukture regija EU na njihovu ekonomsku respondibilnost. Pored toga predstavit će s i prijedlozi u kojem smjeru nastaviti s daljnjim analizama kako bi se pitanje ekonomske respondibilnosti empirijski sagledalo iz više kuteva.

2. Ekonomska respondibilnost

2.1. Prijevod pojma „resilience“

U literaturi se kao prijevod pojma „resilience“ koriste pojmovi kao „otpornost“, „žilavost“ pa čak i „elastičnost“. U ovom radu koristi se „respondibilnost“

Anić (1998) u Rječniku hrvatskoga jezika otpornost definira kao "sposobnost tijela ili čega drugog da se nečemu odupre, izdržljivost". U Englesko-hrvatskom rječniku (1992) pojam "resilience" se definira kao "odskakanje, odbijanje (from od); opružanje, rastezanje; fig uzmah, pokretljivost, opružnost, elastičnost". Također, pojam "resile" definira se kao "vratiti se, uzmicati, ustuknuti, povući se, izmaći, izbjeći; odskočiti, skočiti unatrag, odbiti se, povratiti se (u prvobitni položaj)". Samim time jasno je kako se radi o pojmu koji podrazumijeva određenu dinamičnost. Simmie i Martin (2010) u svom odbijanju ekvilibrističkih pristupa smatraju kako se tvrtke, organizacije i institucije koje čine regionalna gospodarstva konstantno mijenjaju i prilagođavaju svojim ekonomskim ekosustavima.[4]

[4] Ekvilibristički pristupi temelje se na principu sličnom Solowljevu modelu rasta gdje postoji bezbroj postojanih stanja (ekvilibrija), a tranzicijski put između njih zapravo je pomicanje gospodarstva iz jednog stanja u drugo pod utjecajem šokova. Respondibilno gospodarstvo bi prema tome bilo ono koje se uspješno prilagodi, te ili nastavi na razini jednakoj prije šoka ili na još većoj razini dugotrajnog ekvilibrijskog rasta. Gospodarstvo koje nije dovoljno ili je slabo respondibilno u istoj bi se situaciji našlo na znatno nižoj stazi dugotrajnog ekvilibrijskog rasta. Za više, vidjeti Simmie, J. and Martin, R. (2010), „The economic resilience of regions: Towards an evolutionary approach“, Cambridge Journal of Regions, Economy and Society, Vol. 3, pp. 30.

Ramlogan i Metcalfe (2006) jednostavno su to sročili kazavši kako su gospodarstva temeljena i pogonjena znanjem, a znanje nikada ne miruje – kapitalizam je suštinski vrlo nemiran proces. Zašto onda ne „otpornost“.

Anić (1998) u Rječniku hrvatskoga jezika otpornost definira kao "sposobnost tijela ili čega drugog da se nečemu odupre, izdržljivost". Samim time jasno je kako otpor mora biti izazvan, u protivnom tijelo ili subjekt miruje. Autori poput Martina, Simmiea i Briguglia uz pojam resilience kao dodatan argument njezinoj dinamičnosti pridodaju i pojam histereze. Definicija ovog pojma, koji dolazi od grčkog hysteres što znači „nedostatak“, može se naći kod Anića i Goldsteina (2000) koji je u svojem rječniku stranih riječi interpretiraju u tri aspekta: fizičkom, ekonomskom i informatičkom.

Definicija prvog glasi: pojava da rezultati nekog djelovanja traju i po uklanjanju uzročnika toga djelovanja. Drugog: Pretpostavka da naravna stopa nezaposlenosti automatski prati stopu stvarne nezaposlenosti. Trećeg: sklonost uređaja, sklopa ili sustava da se ponaša različito, ovisno o smjeru promjene ulaznog parametra.

U Poslovnom rječniku (1995) grupa autora definira histerezu kao „pojam preuzet iz fizike koji označava pojavu da se materijal promijeni kada je izložen nekom vanjskom utjecaju, a da se potom ne vrati u prvobitno stanje kada se izvor te promjene ukloni“. Dalje, navode kako se „u ekonomiji ovaj efekt svodi na to da sadašnja razina neke varijable ovisi o njenoj prošloj razini: ako poraste nezaposlenost, ona može postati samoodržavajuća iako razlozi koji su je izazvali više ne djeluju“.

Efekt histereze također je uočljiv i u slučaju promjene valutnih tečajeva. Naime, kada se tijekom poslovnih ciklusa dogodi značajnija promjena tečaja koja potraje duže vremena, ona će sigurno ostaviti utjecaja na platnoj bilanci, iako se tečaj vratio na prijašnju razinu. Dakle, radi se o pojmu koji jasno pretpostavlja aspekt dinamičnost. Dinamičnosti koju prijevod poput "otpornost" nema. Zbog toga se smatra kako bi u diskurs bilo optimalnije uvesti pojam "respondibilnost".

No, prije nego se krene u definiciju pojma „respondibilnost“, pitanje je zašto ne u diskurs ubaciti pojam „elastičnost“ - budući da se i on spominje kao jedan od prijevoda pojma „resilience“?
Grupa autora Poslovnog rječnika (1995) definira „elastičnost“ kao sposobnost neke ekonomske veličine y da reagira više ili manje intenzivno na promjenu neke druge veličine x s kojom je u

međuzavisnosti. „Ekonomska veličina y je elastična ako je promjena veličine y intenzivnija od promjene veličine x“ navodi se u Poslovnom rječniku koji uz to definira pojmove kao što su „elastičnost ponude“, „elastičnost ponude rada“, „Elastičnost potražnje za radom“, „elastičnost supstitucije rada kapitalom“.[5]

Babić(2011) uz spomenute pojmove spominje i „elastičnost očekivanja“, „elastičnost poreza“, „elastičnost supstitucije“.[6]

Dakle, iako je vidljivo da je ispunjen uvjet reagiranja na izvanjski stimulans, kod elastičnosti se ipak radi o svojevrsnom podražaju jedne varijable, ekonomske veličine, na drugu. Također, smatra se, diskutabilno je kako ni pojmom „elastičnosti“ nije dovoljno obuhvaćen dinamički aspekt koji bi trebao formirati skup povezanih, ali i nepovezanih mjera, politika, institucija i aktivnosti uspostavljenih i poduzetih prije, za vrijeme i poslije krize, donesenih od strane i privatnog i javnog sektora, koje ekonomskim entitetima omogućavaju što optimalniju apsorpciju i oporavak od egzogenih šokova.

Tu ulogu, smatra se u ovom radu, ispunjava pojam „respondibilnost“.

Njegova definicija direktno proizlazi i naslanja se na definiciju pojma respondirati (od lat. respondere - koji odgovara). Klaić (2007) "respondirati" definira kao "odgovarati, odgovoriti; slagati se, podudarati se; biti prikladan, pristajati, biti dorastao". Također definira izraz "respondibilan" kao "odgovarajući, odgovoran, prikladan, razmjeran, podjednak, podudaran, sukladan; pristao, dorastao". Anić i Goldstein (2000) pod pojmom "respondibilan" podrazumijevaju nešto što odgovara potrebi, što je prikladno, sukladno, a pod pojmom "respondirati" imaju dvije verzije. Prva obuhvaća definiciju "pristajati dobro uz što, poklapati se s drugim, suglasiti se s kim; odgovarati, podudarati se, slagati se. U drugoj se nalazi definicija "biti u skladu s kim ili čim; pristajati".

[5] Za više vidjeti Jurković, P., Luković, F., Pribičević, Đ. i Ravlić, S. (1995), „Poslovni rječnik“, str. 126-127, Masmedia, Zagreb

[6] Za više vidjeti Babić, M. (2011), „Ekonomija: uvod u analizu i politiku“, drugo dorađeno izdanje, str. 100, 321, 435, Znanje d.o.o., Zagreb

2.2. O ekonomskoj respondibilnosti

Respondibilnost je, kako se konstatira u analizi iz Izvješća (2014) fenomen koji se može gledati na globalnoj, ali i na lokalnoj razini gdje susjedna područja u ovisnosti o specifičnim teritorijalno-socijalno-demografskim parametrima mogu ispoljiti različite stupnjeve ekonomske respondibilnosti.

Smatra se kako neke regije bolje podnose eksterne šokove zbog visoke razine ekonomske respondibilnosti (eng. economic resilience) koja istim regijama omogućuje da podnesu, izdrže i oporave se od pada sveopće gospodarske aktivnosti u okruženju. Briguglio (2007) u svojoj prezentaciji pripremljenoj za Forum malih Država održanom na Malti u sklopu konferencije „Building the economic resilience of small states definira „economic resilience“ ili ekonomsku respondibilnost kao „skup djelovanja koje poduzimaju donosioci odluka (policy makers) i privatni ekonomski entiteti, a koji omogućuje državi da odupre se, izdrži i oporavi se od negativnih efekata egzogenih šokova. Da ekonomska respondibilnost oblikuje adaptivne kapacitete regije zahvaljujući kojima se uspješno nosi i oporavlja od eksternih šokova slaže se i grupa autora u Izvješću (2014).

Martin(2011) smatra da bi za potpun odgovor na pitanje „zašto neke regije imaju veći stupanj ekonomske respondibilnosti od drugih) trebalo napraviti analizu reakcija lokalnih tvrtkih i radne snage na eksterne šokove. To potkrjepljuje tezom kako tvrtke kao jedan od osnovnih odgovora na recesiju koriste otpuštanje radnika. No, nakon što je kriza prošla, te iste tvrtke nastavljaju funkcionirati s istom količinom radne snage. Ako višak radnika na tržištu rada ne pronađe posao za vrijeme oporavka, logično, zaključuje Martin, sav teret ekonomske krize snosit će lokalna radna snaga.

Također, Martin ovdje radi segregaciju ekonomskih aktivnosti pojedine regije tvrdeći kako jedna regija može imati visoku razinu ekonomske respondibilnosti u jednom aspektu (poslovanje tvrtki iz spomenutog primjera), dok kod druge ekonomske varijable (zaposlenost) može imati vrlo nisku razinu respondibilnosti.

Kako se respondibilnost planira dovesti u vezu s nižim stupnjem ekonomskog oštećenja valja obratiti pažnju na same indikatore istog. Prema Teritorijalnom izvješću (2014) jasni indikatori ekonomskog oštećenja bili su pad potražnje, pad ekonomskog outputa i porast nezaposlenosti.

Stoga autori Teritorijalnog izvješća (2014) zaključuju kako diversificirana ekonomija pruža veću regionalnu ekonomsku respondibilnost na eksterne šokove. Primjerice, za vrijeme zadnje velike krize, pad građevinskog sektora imao je velike negativne implikacije na regije kojima je građevinski sektor bitna komponenta sveopće ekonomske aktivnosti.

Poremećaje ekonomskog rasta izazvane eksternim šokovima teško je, gotovo nemoguće, predvidjeti. Ako razdoblja kontrakcija i ekspanzija (kratkoročne ekonomske fluktuacije) ne možemo predvidjeti, pa čak niti identificirati u realnom vremenu postavlja se pitanje što zapravo možemo? Jer, nešto se mora napraviti kako bi se, ako ne spriječilo, onda barem ublažilo ulazak u recesiju koju Babić (2011) definira kao proces smanjenja proizvodnje i porasta nezaposlenosti.

Štoviše, ocjene o tome gdje se agregatna ekonomska aktivnost točno nalazi, je li upala u recesiju i koliko je duboko u njoj daje poseban odbor. Kako navode Čorić i Malešević(2013), proglašavanje recesija nije niti malo trivijalno, zbog čega postoji poseban odbor, NBER-ov odbor za datiranje poslovnih ciklusa (NBER BCD odnosno eng.National Bureau of Economic Research Business Cycle Dating Comitte.I upravo je on zadužen za "a posteriori" datiranje poslovnih ciklusa. Autori Čorić i Malešević (2013) konstatiraju kako je spomenuti odbor prilično pažljiv glede vremenskog okvira prekretnica gdje poslovni ciklus prelazi iz ekspanzije u kontrakciju (i obrnuto), te "ne donosi odluke u realnom vremenu, nego sa zakašnjenjem jer čekaju da im sve informacije budu dostupne, te da se objave prve revizije podataka".[7]

Predviđanje toka agregatne ekonomske aktivnosti omogućuje donositeljima odluka da na vrijeme mogu poduzimati potrebne korake radi usmjeravanja privrednih kretanja u poželjnom pravcu, kao i određivanje najpovoljnijeg između više alternativnih pravaca razvitka konjunkture. Kako argumentira Babić (2001) za ekonomsku je politiku od posebne važnosti, što je moguće ranije utvrđivanje vremena ciklusnih prekretnica (eng. turning points), kako bi se odgovarajućim mjerama ekonomske politike njihovi društveni troškovi minimizirali. Pri tome dodaje kako je jedna o najčešćih metoda koja se pri tome koristila Harvardska metoda, odnosno barometarsko predviđanje (Babić 2001).[8]

[7] Za više pogledati Čorić, B., and Perović, M.L. (2013), „Makroekonomija: Teorija i politika“, str. 95-102, Sveučilište u Splitu, Ekonomski fakultet, Split

[8] Za više vidjeti Babić, M. (2011), „Ekonomija: uvod u analizu i politiku“, str. 623-626, drugo dorađeno izdanje, Znanje d.o.o., Zagreb.

Hermansen i Röhn (2015), argumentiraju kako se zadnjih nekoliko desetljeća povećala nesigurnost, koja se ogleda u pojavi financijskih kriza i visokih troškova u razinama proizvodnje, te fluktuaciji u broju zaposlenika koji vode prema smanjenju produktivnosti kod poduzeća.[9]

To dovodi do neefikasnog trošenja sredstava od strane lokalnih vlasti,. U najgorem slučaju, oni koji su izgubili posao u jednoj regiji potražit će poslove u drugoj što automatski dovodi do smanjenih prihoda od poreza što će gospodarstvo učiniti još ranjivijim.

Kako stoji u Teritorijalnom izvještaju (2014) ekonomska kriza koja je započela 2008. godine uzrokovala je najveće usporavanje i pad agregatne ekonomske aktivnosti u povijesti Europske unije. Dovela je do zastoja u dugoročnim trendovima konvergencije BDP-a kao i stopa zaposlenosti među državama članicama. Utjecaj krize vrlo je dobro dokumentiran širom cijele Europske unije, a jasni indikatori ekonomskog oštećenja bili su pad potražnje, pad ekonomskog outputa i porast nezaposlenosti.

Briguglio (2007) u svojoj prezentaciji pripremljenoj za Forum Malih Država održanom na Malti u sklopu konferencije „Building the economic resilience of small states" naglašava kako se na ekonomsku respondibilnost može gledati kroz odgovarajuće mjere i intervencije poduzete kako bi se osigurala odgovarajuća politika u četiri područja: mikroekonomska stabilnost, učinkovitost mikroekonomskog tržišta, dobrog upravljanja regionalne uprave, te društvenog razvoja.

Na istoj se konferenciji diskutiralo o razvijanju metode za procjenu rizika i stupnja oštećenja koje bi vanjski šokovi mogli nanijeti gospodarstva malih država pa čak i regija. Pored ekonomske respondibilnosti (resilience) unijeli su i pojam ekonomske ranjivosti koja je definirana kao „nasljedna osobina, stanje koje utječe na izloženost određene zemlje egzogenim šokovima, a koja uključuje visok stupanj ekonomske otvorenosti, visoke zavisnosti o strateški važnom uvozu (uključujući energente i hranu), kao i visoki stupanj koncentracije izvoza.[10]

[9] Za više vidjeti Hermansen, M. and Röhn, O. (2015), „Economic resilience: The usefulness of early warning indicators in OECD countries", *OECD Economics Department Working Papers*, No. 1250.
[10] Što se ekonomske ranjivosti tiče u Regionalnom ekonomskom izvještaju (2014) MMF-a navodi se kako su Hrvatska, Mađarska, Srbija, Bjelorusija, Ukrajina i Turska i dalje relativno u većem riziku od eksternih financijskih šokova od ostalih zemalja centralne, istočne i jugoistočne Europe.

„Economic resilience“ ili ekonomska respondibilnost definirana je na istoj konferenciji kao „skup djelovanja koje poduzimaju donosioci odluka (policy makers) i privatni ekonomski entiteti, a koji omogućuje državi da odupre se, izdrži i oporavi se od negativnih efekata egzogenih šokova.

Zaključci prezentirani na konferenciji na Malti[11] rezultat su ranijeg rada Briguglia (2004) u kojem autor na temelju ekonomske ranjivosti i ekonomske respondibilnosti razlikuje četiri moguća scenarija u koje bi se moglo svrstati države. Radi se o scenarijima: Najboljeg slučaja (best case), Najgoreg slučaja (worst case), Samostvorenom (self-made), te Scenariju razmetnog sina (prodigal son).

U „best case“ scenariju nalaze se one države koje nisu nasljedno ekonomski ranjive i koje ulažu u svoju ekonomsku respondibilnost. U „worst case“ scenariju, logično, nalaze se države s jakom nasljednom ekonomskom ranjivosti, ne gotovo nikakvim postojanjem ulaganja u razvijanje ekonomske respondibilnosti. U „self-made“ scenarij možemo svrstati one države koje imaju visok stupanj nasljedne ekonomske ranjivosti ali u isto vrijeme ekonomski su respondibilne zbog prihvaćanja i implementacije različitih akcijskih planova i politika koje im omogućuju nositi se sa šokovima. U „prodigal son“ scenarij spadaju države s niskim stupnjem nasljedne ekonomske ranjivosti ali čiji akcijski planovi i politike ne obuhvaćaju ulaganje u ekonomsku respondibilnost čime se stupanj izloženosti šokovima i njihovim posljedicama povećava višestruko.

2.3. Ekonomska respondibilnost i razina zaposlenosti

Hill et al. (2011) napravili su procjenu kakvi sve faktori čine pojedine regije manje ili više sposobnima apsorbirati egzogene šokove. Ili, što ih čini manje ili više ekonomski respondibilnima. Testirali su široku paleta ekonomskih varijabli, koje, prema njima, determiniraju ekonomske performanse pojedine regije. Neke od njih su: industrijska diversifikacija, zaposlenost, prijašnje stope rasta, vještina i obrazovanost radne snage, demografske karakteristike, gustoća naseljenosti, prihodovna nejednakost.

[11] Glavni ishod konferencije na Malti bio je dizajniranje resilience indeksa (respondibilnosti) kojeg se može koristi u vidu olakšanog donošenja potrebnih politika i akcija za izgradnju i razvijanje respondibilnosti. Za više vidjeti Briguglio, L. (2007), „Building the economic resilience of small states“, presentation prepared for the 2007 Small States Forum, The World Bank, Washington.

Između ostalog su iz analize zaključili kako „regije s visokim stupnjem zaposlenosti u industriji su podložnije egzogenim šokovima ali su zato respondibilnije po pitanju same zaposlenosti zbog cikličke prirode potražnje.

Fagerberg, Verspagen i Caneils (1997) su zamijetili usporavanje konvergencije BDP-a po glavi stanovnika diljem Europske unije krajem osamdesetih godina prošlog stoljeća. BDP po glavi stanovnika u to vrijeme najsiromašnije regije bio je manji od četvrtine BDP-a po glavi stanovnika najbogatije regije.[12]

Autori naznačuju da je to povezano s razlikama u razinama zaposlenosti. Štoviše, doveli su rast BDP-a po glavi stanovnika u ovisnost s rastom zaposlenosti ali i migracijskim tokovima. Veći rast BDP-a po glavi stanovnika vjerojatno će dovesti do generiranja novih poslova, a takvo stanje na tržištu rada generalno je prepoznata kao impuls selidbi radne snage iz mjesta gdje je višak ponude rada prema mjestima s viškom potražnje za radom. Na kraju se to opet odražava na BDP po glavi stanovnika.

Zaposlenost kao temeljnu varijablu analize i na kojoj se temelji izračun indeksa osjetljvosti koji je postao svojevrsnim metodološkim okvirom za studije poslije njihovih, koristili su Martin (2012) i Fingleton et al.(2012) u svojim radovima.

U svojim su radovima došli do zaključka da je različiti stupanj ekonomske respondibilnosti zapravo razlog zbog kojeg regije iste zemlje karakterizira različit stupanj ekonomske uspješnosti. Fingleton (2012) tvrdi da se upravo analiziranjem respondibilnosti mogu bolje shvatiti regionalni dispariteti.[13]

2.3.1. Indeks osjetljivosti

Martin (2012) i Fingleton et al.(2012) razvili su indeks osjetljivosti koji je studijama nakon njihovih pružio idealan metodološki okvir. Naime Martin (2012) i Fingleton et al. (2012). Radi se o jednostavnom načinu mjerenja ekonomske respondibilnosti, a za to su koristili razinu zaposlenosti. Postavili se u odgovarajuću jednadžbu postotne promjene zaposlenosti u

[12] Uzorak se sastojao od 64 europske regije iz četiri države: (Zapadne) Njemačke, Francuske, Italije i Španjolske, za više vidjeti Fagberg, J., Verspagen, B., Caniëls (1997), „Technology, Growth and Unemployment across European Regions“, Regional Studies, vol. 31.5, pp. 457-466

[13] Za više vidjeti Fingleton B., Garretsen H, Martin R. (2012), „Recessionary shocks and regional employment: evidence on the resilience of U.K. regions“, Regional Science 52, str. 109-133)

regijama, te postotne promjene u pripadajućim im državama. Te dvije veličine su podijelili, te su došli do indeksa (β_R). On prikazuje dinamiku ekonomske respondibilnosti kao omjer koeficijenta dinamike zaposlenosti regije i koeficijenta dinamike zaposlenosti države.

Taj su metodološki okvir koristili i Cellini i Torrisi (2014) koji su u svojem radu u vrlo dugom vremenskom nizu analizirali regionalnu respondibilnost u Italiji. No, umjesto razine zaposlenosti, oni su u istoj formuli koristili rast BDP-a, te rast BDP-a per capita, dok je Fingleton (2012), primjerice, koristio logaritam razine zaposlenosti i njezinu stopu rasta.

Cellini i torrisi (2014) u svojem radu smatraju kako analiza koju je Fingleton et al. (2014) proveo ne nudi dovoljna objašnjenja različitih gospodarskih performansi koje se javljaju kroz talijanske regije. Ustanovili su kako „reagiranje regije na šok i oporavak regije od šoka variraju značajnije samo u nekoliko slučajeva usporedbe regija“.

No, Fingleton i Martin u svojim su radovima pokazali kako su β koeficijenti, koji predstavljaju indeks osjetljivosti, kroz promatrane regije za svaki k-ti šok različiti. Zbog tgoa je svaka reakcija regije i utjecaj šoka na nju različiti. Fingleton et al. (2012) je došao do sličnog zaključka kao Cellini i Torrisi ali u pogledu ponašanja regije nakon šoka, gdje je ustanovio kako regije Ujedinjenog Kraljevstva „pokazuju različitu respondibilnost na šokove, ali da su im ponašanja slična u vremenu oporavka“.

3. REGIJE I REGIONALIZAM U EKONOMSKOM SMISLU

3.1. Regije kao oblikovatelji ekonomske aktivnosti

Termin regija odnosi se na subnacionalnu teritorijalnu jedinicu definiranu prema EUROSTAT-ovoj nomenklaturi koja se temelji na NUTS sistemu.

Svaka je zemlja članica Europske unije podijeljena na NUTS 1 regije ili regiju, koja je zatim podijeljena na NUTS 2 regije, a ove su podijeljene na NUTS 3 regije. Svaka pojedinačna regija ima svoje i oznaku, a u radu je i priložena tablica koje su regije korištene za analizu. Neke zemlje, poput Estonije čine samo jednu NUTS 2 regiju.

Dory (2008) smatra kako ovaj sistem ima nekoliko ugrađenih slabosti, ali da je jedini standardizirani i samim time pouzdani oblik prikupljanja podataka na pod državnoj razini za cijelu Europsku uniju. Samim time jedini je prikladan za korištenje u ovom radu i ostalim radovima slične ili bliske tematike.[14]

Radi lakšeg praćenja ekonomskih performansi, pak, u ovom radu će se koristiti metodologija podjele regija prema NACE nomenklaturi koja će pružiti jedan od temelja empirijske analize.

Zašto tipizacija regija? Radi lakšeg praćenja njihovih ekonomskih aktivnosti kao i ekonomskih performansi. Dory (2008) tvrdi kako ekonomije/gospodarstva regija unutar Europske unije ispoljavaju „strukturne sličnosti unutar vlastitog konvergencijskog kluba“ koje potom referiramo kao tipove. Ti tipovi, stoga, imaju nasljedne socio-ekonomske atribute koji ostaju relativno nepromijenjeni tijekom dugog roka (npr. veličina populacije, razina obrazovanja, industrijska struktura). Valja dodati kako se u Izvješću (2014) na regije referira kao na „oblikovatelje ekonomske aktivnosti određene države, a ne samo poligoni za njezino ispoljavanje“. Zbog toga su teritorijalne karakteristike ekonomskih varijabli važne.

Posljedice zadnje ekonomske krize koja je počela 2008. godine i njihova raznolikost kojim su se manifestirale na regije diljem Europske unije u fokus stvaraju pojačani interes istraživača i analitičara za regijama i razlozima zbog čega su neke od njih sposobne bolje podnijeti eksterne šokove i brže se oporaviti od drugih. Naime, kako tvrdi Martin (2011), zadnjih se desetljeća fokus pomaknuo s detaljnog proučavanja ciklusa na utjecaj kojeg eksterni šokovi imaju na

[14] Regije u ovom radu označavat će statističke regije NUTS, te posebice tzv. NUTS-II regije. U analizi se koriste podaci za svih 28 zemalja članica EU

regije. Na konvergenciju i divergenciju regija, preciznije. No, argumentira, zadnjih 30 godina dogodile su se tri velike recesije: u ranim 80-im, ranim 90-im, te naposljetku ova zadnja koja je započela 2008. godine. Sam Martin prepoznaje i prsnuće dot-com balona“ (eng. Dot-com bubble) kao fluktuaciju agregatne ekonomske aktivnosti, no ono je najviše utjecaja imalo u SAD-u, te nije imalo svjetski karakter kao recesije spomenute prije. Zbog toga smatra kako pitanje „regionalne osjetljivosti na eksterne šokove nikada nije bilo aktualnije“.

Grdešić (2013) u svom radu konstatira kako je regionalna politika Europske unije posebno zanimljiva istraživačima i to kao pokušaj da se konvergencijom novih i starih članica uklone dispariteti u razvoju. Dodaje kako je praktičan rad na problemu regionalnog razvoja u Europskoj uniji uvelike olakšan javnom dostupnošću podataka na NUTS1,2,3 razinama.

Tako se, navodi se u Teritorijalnom Izvješću (2014), na NUTS 2 razini mogu promatrati daleko heterogeniji uzorci ekonomske respondibilnosti. Na primjer, u Irskoj postoji jaki kontrast između ekonomskih performansi metropolitanskog područja Dublina i ostatka zemlje. Slično je i u Pugliji u Italiji gdje ruralni dijelovi teritorija imaju jači stupanj ekonomske respondibilnosti od urbanih centara.

Također, autori Teritorijalnog Izvješća (2014) navode kako se zna dogoditi da stupanj ekonomske respondibilnosti regije često zna odgovarati stupnju ekonomske respondibilnosti države. Tvrde kako je „prostorna dimenzija ekonomske respondibilnosti očito pod utjecajem parametara na razini države“. No, to nije slučaj za sve regije.

Iako postoji jasna i precizna tipizacija regija, i dalje ne postoji točno definiran paket akcija i politika koji bi se mogao implementirati na regiju a s ciljem poboljšavanja njene ekonomske respondibilnosti. Razlozi tome su jednostavni – teritorijalna raznolikost i raspored regija, kao i sama priroda eksternih šokova od kojih nijedan nije apsolutno identičan drugome. Također niti jedna regija ne može na eksterni šok odgovoriti na isti način na koji je to uradila neka druga regija.

3.2. Specijalizacija regija

Studija pod nazivom „Analysis of the main factors of regional growth: An in-depth study of the best and worst performing regions“ (2012) pokazala je kako je opravdano razmatrati ekonomske performanse određene regije kroz prizmu razlika u ekonomskoj strukturi koje, u njihovom slučaju, definiraju šest tipova regija[15]: 1. Poljoprivredne regije; 2. Regije zasnovane na nisko i srednje nisko razvijenim tehničkim karakteristikama prerađivačke industrije; 3. Regije zasnovane na visoko i srednje visoko razvijenim tehničkim karakteristikama prerađivačke industrije; 4.Turističke regije; 5. Regije zasnovane na financijskim i poslovnim uslugama; 6. Regije zasnovane na osnovnim uslugama.

Dissart (2003) je u svom radu zabilježio i konstataciju Windta (1992) prema kojoj „povećana specijalizacija regije povećava cikličku nestabilnost“, a također je prenio i zaključke Malizie i Ke (1993) u kojima, između ostalog stoji kako „veća industrijska diversificiranost vodi do nižih stopa nezaposlenosti i manje nestabilnosti tržišta rada; veća stopa rasta rezultira većom nesigurnošću stope zaposlenja“. Dissart (2003) također u svom radu na jednom mjestu sumira i citira određen broj zaključaka brojnih studija o gospodarstvima regija počevši još od 1930. pa naovamo. Tako je zabilježio konstataciju Hackbarta i Andersona (1975) u kojoj stoji kako „Veće regije imaju uravnoteženiju strukturu zaposlenosti od manjih, više specijaliziranih regija“.

Sensier, Healy, Bristow (2014) u zaključcima svoje analize konstatirali su četiri ključna faktora koji odlikuju regije s dobro razvijenom ekonomskom respondibilnošću. To su diversificiranost , razina vještina radne snage, razina inovacija, dobro donošenje odluka od strane kako menadžera u tvrtkama tako i predstavnika regionalnih vlasti. Sve ovo su sastavni dijelovi specijalizacije (manje ili veće) pojedine regije.

Sensier i Artis (2016) su analizirali zaposlenost Walesa u odnosu na zaposlenost Ujedinjenog Kraljevstva i to kvantificirajući metodološki okvir kojeg je postavio Martin (2012). Njihova analiza pokazala je kako je velška zaposlenost bila manje otporna, manje ekonomski respondibilna na šokove od zaposlenosti UK-a. No, konstatirali su kako je velško gospodarstvo nakon recesije iz 1980. godine prošlo kroz procese reorijentacije u kojem su prosječni udjeli

[15] „Analysis of the main factors of regional growth: An in-depth study of the best and worst performing regions“, (2012), A final report for the European Commission, Directorate General Regional Policy, Executive Summary, str. 9, Cambridge Econometrics

zaposlenja u proizvodnji opali, a porasla je razina poslova u uslužnim djelatnostima. Wales je s takvom strukturom zaposlenosti (koja se može tumačiti i kao promjena specijalizacije) dočekao recesije iz 1990. te 2008. godine, te se pokazalo kako je njihov negativan utjecaj bio bitno manji na gospodarstvo Walesa, nego što je to bio slučaj s prethodnim recesijama. Pored toga, vrijeme oporavka, odnosno povratka na razine zaposlenosti prije krize gotovo je bilo prepolovljeno.

Do sličnih zaključaka došao je i Martin et al. (2013) koji zaključuje kako različiti tipovi gospodarstava imaju različite stupnjeve elastičnosti po pitanju potražnje, različite izvozne orijentacije, različite vrijednosti ljudskog kapitala, kao i različite razine izloženosti vanjskoj konkurenciji. I, iz toga, poentira, može se zaključiti kako diversificirana ekonomija ne samo da će smanjiti ranjivost regije prema eksternim šokovima, već će omogućiti znatno brži oporavak iste nakon recesija.

4. EMPIRIJSKI MODEL ODNOSA EKONOMSKE RESPONIBILNOSTI REGIJA EUROPSKE UNIJE I NJIHOVE GOSPODARSKE STRUKTURE

4.1. Prostorna i vremenska definicija uzorka

Analiza je provedena na NUTS 2 regijama Europske unije u statističkom programu STATA. Promatrani vremenski period proteže se od 2001. do 2014. godine. Razlog zbog kojeg se u analizi ne radi s duljim vremenskim nizom, a zbog kojeg bi analiza dala preciznije rezultate leži u nedostupnosti podataka za promatrane varijable. Naime, taj vremenski period bio je najdulji u Eurostatovoj bazi podataka, a da je obuhvaćao sve potrebne varijable

Podaci su prikupljeni s internetskih stranica Eurostata[16] (fusnota – ec.europa.eu/eurostat, kada su prikupljeni), a obuhvaćaju kretanje (rast/pad): zaposlenosti (kao one opće tako i sektorske), BDP-a, BDP-a per capita, investicija, R&D-ja, rasta stanovništva, razine tercijarnog obrazovanja, bruto investicija i investicija. Pojedini podaci poput razine i promjene zaposlenosti gledani su s EU28 razine, zatim državne razine, te na kraju s regionalne razine. To je bilo potrebno da bi se uspješno mogli izračunati indeksi specijalizacije i indeksi osjetljivosti. Podaci o ostalim navedenim varijablama odnose se na NUTS 2 regije Europske unije.

[16] Prikupljeno sa www. ec.europa.eu/eurostat na datum 16., 20., 21. kolovoza 2016.

4.2. Uzorak istraživanja

Analiziran je uzorak od 290 regija NUTS 2 razine Europske unije, te 28 zemalja članica EU. Postoje tri stupnja NUTS sustava koji predstavlja hijerarhijsku klasifikaciju koja svaku članicu Europske unije dijeli na NUTS 1, NUTS 2 i NUTS 3 razine. Radi se o administrativnim jedinicama formiranih na takav način prvenstveno s ciljem prikupljanja, razvoja i usklađivanja regionalne statistike Europske unije, sociološko-ekonomske analize, te postavljanja što preciznijih i kvalitetnijih temeljan za razvoj regionalne politike Unije. Pri tome valja napomenuti kako se prilikom klasifikacije vodilo računa o tome da se administrativne i prirodno geografske jedinice u zemljama ranijim članicama EU uzete kao statističke jedinice , a svakoj od članica pojedino je dan izbor za podjelu na administrativne i statističke jedinice.

Klasifikacija NUTS regija vrši se po broju stanovništva. Tako se NUTS 1 definiraju kao regije koje imaju minimalno tri milijuna, a maksimalno sedam milijuna stanovnika. NUTS 2 regije imaju minimalno 800 tisuća, a maksimalno tri milijuna stanovnika, dok regije na NUTS 3 razinama imaju minimalno 150 tisuća, a maksimalno 800 tisuća stanovnika.

Tablica 1: Tabelarni prikaz karakteristika regija na sve tri NUTS razine

Razina	Min. stanovnika	Maks. stanovnika	Prosječna površina
NUTS 1	3 000 000	7 000 000	45.400 km^2
NUTS 2	800.000	3 000 000	16.310 km^2
NUTS 3	150.000	800.00	3.400 km^2

Izvor: Prikaz autora

Istraživanje je izvršeno na uzorku od 290 NUTS2 regija, odnosno na onolikom uzorku koliki nam se nudio u Eurostatovoj bazi podataka. Valja napomenuti kako u nemalom broju slučajeva uopće nije bilo dostupnih podataka za pojedine regije ili u cijelom promatranom periodu između 2001. i 2014. godine, ili samo za neku od tih godina. To je ujedno i razlog zbog kojeg je odgovarajući model u analizu uzeo manji broj grupa nego što ih zapravo ima, i zbog čega je zabilježen manji broj opservacija od maksimalnog.

Tablica 2: Popis regija uključenih u analizu

Redni broj	**Regija**	Redni broj	**Regija**	Redni broj	**Regija**	Redni broj	**Regija**
1	**BE10**	46	**DE50**	92	**ES23**	138	**ITC2**
2	**BE21**	47	**DE60**	93	**ES24**	139	**ITC3**
3	**BE22**	48	**DE71**	94	**ES30**	140	**ITC4**
4	**BE23**	49	**DE72**	95	**ES41**	141	**ITH1**
5	**BE24**	50	**DE73**	96	**ES42**	142	**ITH2**
6	**BE25**	51	**DE80**	97	**ES43**	143	**ITH3**
7	**BE31**	52	**DE91**	98	**ES51**	144	**ITH4**
8	**BE32**	53	**DE92**	99	**ES52**	145	**ITH5**
9	**BE33**	54	**DE93**	100	**ES53**	146	**ITI1**
10	**BE34**	55	**DE94**	101	**ES61**	147	**ITI2**
11	**BE35**	56	**DEA1**	102	**ES62**	148	**ITI3**
12	**BEZZ**	57	**DEA2**	103	**ES63**	149	**ITI4**
13	**BG31**	58	**DEA3**	104	**ES64**	150	**ITF1**
14	**BG32**	59	**DEA4**	105	**ES70**	151	**ITF2**
15	**BG33**	60	**DEA5**	106	**ESZZ**	152	**ITF3**
16	**BG34**	61	**DEB1**	107	**FR10**	153	**ITF4**
17	**BG41**	62	**DEB2**	108	**FR21**	154	**ITF5**
18	**BG42**	63	**DEB3**	109	**FR22**	155	**ITF6**
19	**CZ01**	64	**DEC0**	110	**FR23**	156	**ITG1**
20	**CZ02**	65	**DED2**	111	**FR24**	157	**ITG2**
21	**CZ03**	66	**DED4**	112	**FR25**	158	**ITZZ**
22	**CZ04**	67	**DED5**	113	**FR26**	159	**CY00**
23	**CZ05**	68	**DEE0**	114	**FR30**	160	**LV00**
24	**CZ06**	69	**DEF0**	115	**FR41**	161	**LVZZ**
25	**CZ07**	70	**DEG0**	116	**FR42**	162	**LT00**
26	**CZ08**	71	**EE00**	117	**FR43**	163	**LU00**
27	**DK01**	72	**IE01**	118	**FR51**	164	**HU10**
28	**DK02**	73	**IE02**	119	**FR52**	165	**HU21**
29	**DK03**	74	**EL51**	120	**FR53**	166	**HU22**
30	**DK04**	75	**EL52**	121	**FR61**	167	**HU23**
31	**DK05**	76	**EL53**	122	**FR62**	168	**HU31**
32	**DKZZ**	77	**EL54**	123	**FR63**	169	**HU32**
33	**DE11**	78	**EL61**	124	**FR71**	170	**HU33**
34	**DE12**	79	**EL62**	125	**FR72**	171	**MT00**
35	**DE13**	80	**EL63**	126	**FR81**	172	**MTZZ**
36	**DE14**	81	**EL64**	127	**FR82**	173	**NL11**
37	**DE21**	82	**EL65**	128	**FR83**	174	**NL12**
38	**DE22**	83	**EL30**	129	**FRA1**	175	**NL13**
39	**DE23**	84	**EL41**	130	**FRA2**	176	**NL21**
40	**DE24**	85	**EL42**	131	**FRA3**	177	**NL22**
41	**DE25**	86	**EL43**	132	**FRA4**	178	**NL23**
42	**DE26**	87	**ES11**	133	**FRA5**	179	**NL31**
43	**DE27**	88	**ES12**	134	**FRZZ**	180	**NL32**
44	**DE30**	89	**ES13**	135	**HR03**	181	**NL33**
45	**DE40**	90	**ES21**	136	**HR04**	182	**NL34**
46	**DE50**	91	**ES22**	137	**ITC1**	183	**NL41**

Izvor: Eurostat

Redni broj	Regija	Redni broj	Regija	Redni broj	Regija
184	**NL42**	230	**SI04**	276	**UKJ2**
185	**NLZZ**	231	**SK01**	277	**UKJ3**
186	**AT11**	232	**SK02**	278	**UKJ4**
187	**AT12**	233	**SK03**	279	**UKK1**
188	**AT13**	234	**SK04**	280	**UKK2**
189	**AT21**	235	**FI19**	281	**UKK3**
190	**AT22**	236	**FI1B**	282	**UKK4**
191	**AT31**	237	**FI1C**	283	**UKL1**
192	**AT32**	238	**FI1D**	284	**UKL2**
193	**AT33**	239	**FI20**	285	**UKM2**
194	**AT34**	240	**FIZZ**	286	**UKM3**
195	**ATZZ**	241	**SE11**	287	**UKM5**
196	**PL11**	242	**SE12**	288	**UKM6**
197	**PL12**	243	**SE21**	289	**UKN0**
198	**PL21**	244	**SE22**	290	**UKZZ**
199	**PL22**	245	**SE23**		
200	**PL31**	246	**SE31**		
201	**PL32**	247	**SE32**		
202	**PL33**	248	**SE33**		
203	**PL34**	249	**SEZZ**		
204	**PL41**	250	**UKC1**		
205	**PL42**	251	**UKC2**		
206	**PL43**	252	**UKD1**		
207	**PL51**	253	**UKD3**		
208	**PL52**	254	**UKD4**		
209	**PL61**	255	**UKD6**		
210	**PL62**	256	**UKD7**		
211	**PL63**	257	**UKE1**		
212	**PT11**	258	**UKE2**		
213	**PT15**	259	**UKE3**		
214	**PT16**	260	**UKE4**		
215	**PT17**	261	**UKF1**		
216	**PT18**	262	**UKF2**		
217	**PT20**	263	**UKF3**		
218	**PT30**	264	**UKG1**		
219	**PTZZ**	265	**UKG2**		
220	**RO11**	266	**UKG3**		
221	**RO12**	267	**UKH1**		
222	**RO21**	268	**UKH2**		
223	**RO22**	269	**UKH3**		
224	**RO31**	270	**UKI3**		
225	**RO32**	271	**UKI4**		
226	**RO41**	272	**UKI5**		
227	**RO42**	273	**UKI6**		
228	**ROZZ**	274	**UKI7**		
229	**SI03**	275	**UKJ1**		

Izvor: Eurostat

4.3 Postavke modela

Analiza je, s obzirom na korištenje statističkih metoda podijeljena na tri dijela.

U prvom dijelu analize radilo se o razlici u kvanitativnim podacima raspoređenim u više skupina koje su međusobno neovisne. Korištenje parametrijskih ili neparametrijskih testova ovisilo je o distribuciji podataka. Promatrale su se razlike u indeksu osjetljivosti β_R[17] izračunatom za svaku regiju.

U drugom dijelu, koji se odnosi na glavnu hipotezu (**GH**) i pomoćnu hipotezu (**PH2**), podaci sadrže prostornu komponentu (eng. cross-sectional data) i vremensku komponentu (eng. time-series). A, modeli kojima se oni na prihvatljiv način analiziraju, odnosno u kojima se na adekvatan način može procijeniti utjecaj jedne ili više varijabli na promatranu zavisnu varijablu (u ovom slučaju su dvije, budući da su takve hipoteze) su panel modeli.

Za razliku od multiple regresije, kod panel analize zavisna varijabla mijenja se i po jedinicama promatranja ali i vremenski. Zbog toga se procjene varijabli koje determiniraju zavisnu varijablu smatraju preciznijima. Kako u obzir uzima obje komponente (vremensku i prostornu), panel analiza omogućuje veći broj opservacija.

U trećem dijelu, slično kao i u drugom, panel analizom testirali smo glavnu hipotezu.

Za testiranja druge pomoćne i glavne hipoteze korišten je dinamički panel model, odnosno Arellanov i Bondov procjenitelj. Razlog tome je što su relacije korištenih varijabli dinamičke prirode, odnosno njihova sadašnja vrijednost ovisi o prethodnim vrijednostima te varijable. Također, ovaj je procjenitelj primjeren za procjenu podataka s velikim brojem jedinica promatranja i relativno malim brojem razdoblja, što je konkretno slučaj i u ovoj analizi.

Koristili smo AB procjenitelj od dva koraka jer je robustan na heteroskedastičnost, a efikasniji je od procjenitelja od jednom koraku.

Valjanost instrumenata korištenih u procjeni modela testirali smo Sarganovim testom koji se temelji na pretpostavci da bi reziduali trebali bit nekorelirani sa skupom egzogenih varijabli, u slučaju da se zaista radi o egzogenim instrumentima. Zbog toga je je poželjno prihvaćanje nulte hipoteze koja kaže da su odabrane instrumentalne varijable nekorelirane s rezidualima.

[17] Škrabić Perić, B. (2015), Nastavni materijali iz kolegija „naliza vremenskih serija i panel podataka“. Ekonomski fakultet Split, Split

Odbijanje nulte hipoteze značilo bi da u modelu postoji problem endogenosti. Zbog toga je važan i odabir optimalnog broja instrumenata kako bi se prihvatila nulta hipoteza Sarganovog testa, a da se usto vrijeme ne poveća značajno pristranost procjenitelja.

Osim Sargan testa, provedena su još dva dijagnostička testiranja autokorelacije među prvim diferencijama rezidualnih odstupanja. To su bili testovi *m1* i *m2*.

Nultom hipotezom m1 testa pretpostavlja se nepostojanje autokorelacije prvog reda među prvim diferencijama reziduala, a nultom hipotezom m2 testa pretpostavlja se nepostojanje autokorelacije drugog reda među prvim diferencijama reziduala.[18]

4.3.1. Intenzitet ekonomske respondibilnosti kod NUTS2 regija EU

4.3.1.1. Izračun indeksa osjetljivosti

Jednadžba koju su koristili Martin (2012) i Fingleton et al. (2012) izgleda ovako:

(1.)

$$\beta_R = \frac{\frac{Er_t - Er_{t-1}}{Er_{t-1}}}{\frac{Ed_t - Ed_{t-1}}{Ed_{t-1}}}$$

Pri čemu je:

β_R – Martinov indeks osjetljivosti regije

Er - Razina zaposlenosti u regiji

Ed – Razina zaposlenosti u državi

Za potrebe analize, osim vrijednosti za državu u nazivnik je ujedno uvrštena i vrijednosti prosjeka 28 zemalja članica EU, dakle Europske unije. Tako smo željeli izmjeriti razinu respondibilnosti pojedine regije u odnosu na državu kojoj pripada, ali i u odnosu na čitavu Europsku uniju. Formula tada izgleda identično, samo je umjesto relativne promjene

[18] Škrabić Perić, B. (2015), Nastavni materijali iz kolegija „Analiza vremenskih serija i panel podataka“, Ekonomski fakultet Split, Split

zaposlenosti država postavljena relativna promjena zaposlenosti Europske unije (izračunat za svih 28 država članica.

(2.)

$$\beta_R = \frac{\frac{Er_t - Er_{t-1}}{Er_{t-1}}}{\frac{E(EU28)_t - E(EU28)_{t-1}}{E(EU28)_{t-1}}}$$

Također se željelo ispitati jesu li razlike u ekonomskoj respondibilnosti statistički značajne ako se računaju na razini države, kao i na razini čitave Unije.

4.3.1.2. Signifikantnost razlika ekonomske respondibilnosti

Prvi korak analize bio je testiranje radi li se normalnoj distribuciji ili ne. U slučaju da se radi o normalnoj distribuciji nastavili bi s parametrijskim testovima, u suprotnom bi nastavili s neparametrijskim testovima. Prvo se krenulo analizirati indeks osjetljivosti u čijem računanju je, pored onog iz regija, u nazivniku korištena vrijednost dobivena iz zaposlenosti država. Za to je korištena deskriptivna statistiku uz odgovarajuće testove.

4.3.2. Gospodarska struktura regija i njihov gospodarski rast

4.3.2.1. Izračun indeksa specijalizacije

Indeks specijalizacije izračunali smo preko formule:

(3.)

$$\beta r_j = \frac{\frac{Er_j}{\Sigma Er}}{\frac{Ed_j}{\Sigma Ed}}$$

S tim da je:

βr_j – indeks specijalizacije regije (r) i djelatnosti (j)

Er_j – razina zaposlenosti određene regije (Er) u određenoj djelatnosti (j)

Er – ukupna razina zaposlenosti u određenoj regiji (Er) u svim djelatnostima

Ed_j – razina zaposlenosti države (Ed) u određenoj djelatnosti (j)

Ed – ukupna zaposlenost države u svim djelatnostima

Ako je razina zaposlenosti u određenom sektoru u regiji viša od prosječne razine zaposlenosti u istom sektoru, ali na državnoj razini onda je indeks specijalizacije veći od 1 ($Sr_j>1$).

Preciznije, ako je $\beta<1$ tada se radi o regiji koja je više ekonomski respondibilnija nego država, shodno tome iznos bete veći od jedan ($\beta>1$) predstavlja regiju koja je manje ekonomski respondibilna od države.

Dobivenu veličinu Goschin, Constanin, Roman, Ileanu (2009) (FUSNOTA – U svom radu grupa autora detaljno opisuje četiri indeksa s kojima su detaljno analizirali specijalizaciju i prostornu distribuciju regija u Rumunjskoj[19] nazivaju omjerom specijalizacije koji se vrlo često

[19] Za više, vidjeti Z.Goschin, D. Luminita Constantin, M.Roman, B. Vasile Ileanu (2009), „Specialisation And Concentration Patterns In The Romanian Economy“, Journal Of Applied Quantitative Methods, Vol.4, No.1, str. 95-111

koristi kao baza za sofisticiranije metode izračuna ne samo specijalizacije regija, već i njihovih prostornih distribucija. Ipak, naglašavaju, ti omjeri i sami po sebi mogu pružiti vjernu sliku specijalizacije i prostorne distribucije regija. Upravo je taj „omjer“ kako ga oni zovu bio jedan od temelja analize provedene u Analizi glavnih faktora regionalnog rasta (2012)[20].

Specijaliziranost regija gledala se kroz takozvanu NACE nomenklaturu prema kojoj su se grupirali djelatnosti i koju je korištena za izračun indeksa specijalizacije „r_j“.

Tablica 3: Grupiranje djelatnosti u sklopu NACE nomenklature

NACE nomenklatura (sektori)	Djelatnosti
A	Poljoprivreda, lov, šumarstvo, ribarstvo
B-E	Industrija
F	Građevina
G-N	Distribucija, transport, turizam, usluge u IT industriji, financijama, osiguranju, poslovanje nekretninama...
O-U	Državna administracija, obrana, obrazovni sektor, zdravstveni sekotr, umjetnost, zabava...

Izvor: Eurostat

Kako se radi s pet grupa, izračunalo se i pet indeksa koji su imenovani isto kao i grupe.

Razlog podjele sektora kakva je korištena u analizi leži u činjenici da je podacima tada lakše baratati, a i nije se željela dokazati kakva točno specijaliziranost regije u sklopu s ostalim varijablama koje čine gospodarsku strukturu utječu na gospodarski rast regije, te se ujedno nije željelo dokazati kakva točno specijalizacija (u kojim tono sektorima) više ili manje utječe na ekonomsku respondibilnost regije. Za provesti analizu takvog tipa potrebna je detaljnija podjela sektora, također preko NACE rev. 2 nomenklature, ali i veća dostupnost podataka pri čemu se prvenstveno misli na produljenje vremenskog niza koji bi trebao trajati duže od 14 godina.

Analiza glavnih faktora ekonomskog rasta (2012) kaže da preciznija podjela na sektore ujedno reflektira karakteristike regija koje je vrlo teško obuhvatiti i izračunati sistemskom

[20] „Analysis of the main factors of regional growth: An in-depth study of the best and worst performing regions“, (2012), A final report for the European Commission, Directorate General Regional Policy, Executive Summary, str. 9, Cambridge Econometrics

analizom. Autori također naglašavaju kako je i važno imati na umu kako veći sektorski udio u ukupnoj razini zaposlenosti pojedine regije nužno ne predstavlja kako je upravo ta djelatnost isključivo dominantna u apsolutnim terminima.[21]

4.3.2.2. Utjecaj gospodarske strukture regije na njezin gospodarski rast

Za zavisnu varijablu, koja ujedno i predstavlja gospodarski rast, uzeta je stopa rasta BDP-a (**GDP Growth**). Ona služi kao glavni makroekonomski pokazatelj, preciznije, kao mjerilo gospodarske aktivnosti neke zemlje, u ovom slučaju regije, u određenoj godini. Vrijednosti za ovu varijablu preuzete su sa stranice EUROSTAT[22]. Promjena BDP-a izračunata je odnosu na prethodno razdoblje. Na isti način izračunate su sve ostale varijable u analizi, osim indeksa.

Nezavisne varijable su:

- Indeksi specijalizacije - **A, B-E, F, G-N, O-U**
- BDP per capita – **GDP Growth pc**
- Razina obrazovanja (visoka stručna sprema) – **Obrazovanje Growth**
- Troškovi istraživanja i razvoja u mil. eur – **R&D Growth**
- Troškovi istraživanja i razvoja u eur per capita – **R&D Growth pc**
- Troškovi istraživanja i razvoj u mil. eur – poduzetnički sektor – **R&D Growth (ps)**
- Troškovi istraž. i razvoja u eur per capita – poduz. sektor – **R&D Growth pc (ps)**
- Bruto investicije – **Bruto investicije Growth**
- Investicije – **Investicije Growth**
- Stopa rasta stanovništva – **Stanovništvo Growth**

[21] Posebno se ističu primjeri regija u Nizozemskoj, Belgiji, Njemačkoj, te Ujedinjenom Kraljevstvu. Iako se radi o poljoprivrednim regijama udio zaposlenih u toj djelatnosti ne prelazi 6 posto, te je manji od udjela kojeg nose, primjerice, uslužne djelatnosti. No, te se regije i dalje smatraju specijaliziranima u poljoprivredi zbog toga što je njihov udio u toj zaposlenosti tri puta veći od državnog udjela.

[22] Vrijednosti BDP-a na službenoj Eurostatovoj stranici, što se regija na NUTS 2 razini tiče, nudile su se unazad do 2000. godine, te smo zbog toga promjene mogli izračunati počevši od 2001. godine. Sličan slučaj je bio s većinom podataka.

Indeksi specijalizacije predstavljaju najrelevantniji podatak u analizi budući da će najvećim dijelom upravo oni i definirati karakter gospodarske strukture koja utječe ili ne utječe na gospodarski rast.

BDP per capita je mjera ukupne proizvodnje neke zemlje, u ovom slučaju regije u kojoj je bruto domaći proizvod podijeljen s brojem ljudi u zemlji, u ovom slučaju regiji. Radi se osobito korisnom pokazatelju prilikom uspoređivanja jedne zemlje ili regije s drugom, jer nam pokazuje relativnu uspješnost promatranih entiteta, odnosno koji je razvijeniji. Porast BDP-a per capita se uglavnom interpretira kao povećanje produktivnosti zemlje, ili regije, ovisno što se promatra. Zbog toga smo paralelno analizom u kojoj je stopa rasta BDP-a zavisna, a stopa rasta BDP-a per capita nezavisna varijabla, napravili analizu u kojoj smo ovim varijablama „zamijenili uloge". Dakle, u analizi (analiza **2b**) provedeno je jednako istraživanje samo što je kao zavisna varijabla uzet rast BDP-a per capita, a u grupu nezavisnih varijabli smo uvrstili rast BDP-a.

Razina obrazovanja ujedno označava visinu ljudskog kapital. Wolf i Gittleman (1993)[23] istraživali su korelaciju između obrazovanja i stope rasta BDP-a, te su pokazali kako je tercijarna razina obrazovanja statistički značajna gdje se promatrani uzorak nalazio u srednjem i višem platnom razredu. Kod uzorka u najnižem platnom razredu statistički značajnim se pokazala primarna razina obrazovanja (koja je u Europskoj uniji obvezna).

Troškovi istraživanja i razvoja se promatraju zbog toga što, kako Analiza glavnih faktora regionalnog rasta (2012) tvrdi, je za prijenos na više razine proizvodnje (produktivnije i specijaliziranije) ali i pružanja usluga potrebno ulaganje u istraživanje i razvoj ili R&D. Zbog toga, kako tvrde autori studije, djelovanja državnih, ali regionalnih i lokalnih vlasti trebala bi se usmjeriti i prema tom aspektu. Također je zabilježena i jaka pozitivna korelacija između razina inovacija, poduzetničke kulture te razina ekonomske respondibilnosti.[24]

Investicije su, kako je Rhön et al. (2015) pokazao ključne da se gospodarstvo određene države brže oporavi od šoka. Što su one kvalitetnije, i što ih je više, to je oporavak uspješniji. U analizu je pored rasta općih investicija uključen i rast bruto investicija koje označavaju ukupni iznos

[23] Za više vidjeti Wolff, E., Gittleman, M. (1993), The Role od Education in Productivity Convergence: Does Higher Education Matter, in A.Szimaoi, B. Van Ark i D.Pilat, ed., „Explaining Economic Growth", Elsevier Science Publishers, Amsterdam

[24] „Analysis of the main factors of regional growth: An in-depth study of the best and worst performing regions", (2012), A final report for the European Commission, Directorate General Regional Policy, Executive Summary, str. 9, Cambridge Econometrics

uloženih sredstava u izgradnju novih i rekonstrukciju postojećih kapaciteta, koji se financiraju ne samo iz štednje, odnosno dijela dobiti namijenjenog investiranju, već i iz sredstava amortizacije.

Najvećim se dijelom pod pojmom bruto investicija podrazumijevaju ulaganja u osnovna sredstva, ali ih je zbog značenja ulaganja u trajna obrtna sredstva potrebno tumačiti i kao predujmljivanje ukupno potrebnog kapitala sa svrhom izvedbe investicijskih projekata.[25]

Stopa rasta stanovništva važna je zbog razlika u stopama rasta BDP i BDP-a per capita. Također njenim uvrštavanjem možemo se promotriti je li starenje ili pomlađivanje stanovništva signifikantno utječena gospodarski rast.

Dijkstra i Athanasoglou (2015) u svom izvještaju o napretku regija prema „Europa 2020" ciljevima ističu kako 2020 indeks, kojeg su izračunali u toj studiji, zorno očitava regionalne disparitete. Predočili su podatke koji govore da je taj Indeks (a koji govori koliko je pokoja regija napredovala prema ostvarenju „Europa 2020" ciljeva) dvostruko veći kod razvijenih regija nego kod manje razvijenih. Dijsktraa i Athanasoglou to pripisuju velikim razlikama z zaposlenosti, tercijarnoj razini obrazovanja, te sektoru istraživanja i razvoja. Smatraju kako se ciljevi „Europa 2020" neće moći ostvariti ako se kod manje razvijenih regija ne zabilježi značajan „catching up" pristup.[26]

Jednadžba modela koji će se procjenjivati u daljnjem radu može se zapisati na sljedeći način:

$$Y_{rt} = \beta_0 + \beta_1 * Y_{rt-1} + \beta_2 * X_{1rt} + \beta_3 * X_{2rt} + \beta_4 * X_{3rt} + \beta_5 * X_{4rt} + \beta_6 * X_{5rt} + \beta_7 * X_{6rt} + \beta_8 * X_{7rt} + \beta_9 * X_{8rt} + \beta_{10} * X_{9rt} + \beta_{11} * X_{10rt}$$

Pri čemu je:

Y_{rt} – gospodarski rast zemlje regije „r" u razdoblju „t"

X_{1rt} – BDP per capita regije „r" u razdoblju „t"

X_{2rt} – obrazovanje regije „r" u razdoblju „t"

[25] Definicija preuzeta iz Jurković, P. Et al. (1995), „Poslovni rječnik", dopunjeno izdanje, Masmedia, Zagreb.

[26] Za više vidjeti Dijskstra L., Athanasoglou, S. (2014), „The Europe 2020 Index: The Progress of EU countries, Regions, And Cities To The 2020 Targets", A series of short papaers on regional research an indicators produced by the Directorate-General for Regional and Urban policy, European Comission-

X_{3rt} - troškovi istraživanja i razvoja u eur per capita regije „r“ u razdoblju „t“

X_{4rt} - troškovi istraživanja i razvoja u mil. eur regije „r“ u razdoblju „t“

X_{5rt} - troškovi istraživanja i razvoj per capita (poduzetnički sektor) regije „r“ u razdoblju „t“

X_{6rt} - troškovi istraživanja i razvoj u mil. eur (poduzetnički sektor) regije „r“ u razdoblju „t“

X_{7rt} - bruto investicije regije „r“ u razdoblju „t“

X_{8rt} – investicije regije „r“ u razdoblju „t“

X_{9rt} - stopa rasta stanovništva regije „r“ u razdoblju „t“

X_{10rt} – indeks specijalizacije regije „r“ (**A, B-E, F, G-N, O-U)**

β_1, β_2, β_3, β_4, β_5, β_6, β_7, β_8, β_9, β_{10} – parametri koje treba procijeniti

4.3.3. Gospodarska struktura regija i njihova ekonomska respondibilnost

Treći dio analize tiče se glavne hipoteze i u nju su uvrštene dvije vrste indeksa koji su prethodno izračunati. Kao zavisnu varijablu stavljen je Martinov indeks osjetljivosti koji označava ekonomsku respondibilnost, a u nezavisne varijable uvršteni su indeksi specijalizacije.

Jednadžba modela koji će se procjenjivati u daljnjem radu može se zapisati na sljedeći način:

$$Y_{rt} = \beta_0 + \beta_1 * Y_{rt-1} + \beta_2 * X_{1rt} + \beta_3 * X_{2rt} + \beta_4 * X_{3rt} + \beta_5 * X_{4rt} + \beta_6 * X_{5rt}$$

Pri čemu je:

Y_{rt} – ekonomska respondibilnost (ER) regije „r“ u razdoblju „t“

X_{1rt} – indeks specijalizacije „A“ regije „r“ u razdoblju „t“

X_{2rt} – indeks specijalizacije „B-E“ regije „r“ u razdoblju „t“

X_{3rt} - indeks specijalizacije „F“ regije „r“ u razdoblju „t“

X_{4rt} - indeks specijalizacije „G-N“ regije „r“ u razdoblju „t“

X_{5rt} - indeks specijalizacije „O-U“ regije „r“ u razdoblju „t“

β_1, β_2, β_3, β_4, β_5, β_6 – parametri koje treba procijeniti

4.4. Rezultati istraživanja

4.4.1. Analiza signifikantnosti razlika ekonomske respondibilnosti

Deskriptivnom statistikom utvrđen je broj promatranja, aritmetička sredina, standardna devijacija, te minimum i maksimum.

Tablica 4: Deskriptivna statistika indeksa osjetljivosti

Variable	Obs	Mean	Std. Dev.	Min	Max
beta	3788	.5932471	36.52198	-1583.1	676.14

Izvor: Izračun autora

Nakon toga se Kolmogorov-Smirnov testom utvrdilo je li distribucija normalna ili nije, budući da je o raspodjeli podataka ovisio odabir daljnje metode i tijeka analize.

Tablica 5: Kolmogorov-Smirnov test distribucije indeksa osjetljivosti

Smaller group	*D*	*P-value*	*Corrected*
beta:	*0.3901*	*0.000*	
Cumulative:	*-0.3999*	*0.000*	
Combined K-S:	*0.3999*	*0.000*	**0.000**

Note: ties exist in dataset, there are 1100 unique values out of 3788 observations

Izvor: Izračun autora

Iz Kolmogorov-Smirnov testa evidentno je kako je $p< 0,05$ što indicira da se ne radi o normalnoj distribuciji, te daljnja analiza izvršila Kruskal-Wallis testom koji je neparametrijski test.

Tablica 6: Kruskal-Wallis test

Kruskal-Wallis equality-of-populations rank test
chi-squared = 435.238 with 283 d.f.
probability = **0.0001**
chi-squared with ties = 435.247 with 283 d.f.
probability = **0.0001**

Izvor: Izrada autora

Budući da je p< 0,05, vrijednost Kruskal-Wallis testa potvrdila je kako postoje statistički značajne razlike u ekonomskoj respondibilnosti između regija Eurospke unije.

Ista analiza kao ovu prethodno opisana izvršena je i na indeksu osjetljivosti kojeg smo dobili stavljajući u omjer koeficijente dinamike zaposlenosti regija i prosjeka Europske unije. I u tom slučaju je vrijednost Kruskal-Wallis testa potvrdila kako postoje statistički značajne razlike u ekonomskoj respondibilnosti između regija Europske unije. Samim time **potvrđena je** i prva pomoćna hipoteza **(PH1)** koja glasi: **Regije Europske unije bilježe signifikantne razlike u intenzitetu ekonomske respondibilnosti.**

4.4.2. Analiza odnosa gospodarske strukture regija EU i njhovog gospodarskog rasta

Za testiranje druge pomoćne hipoteze (PH 2) korišten je dinamički model na odabranom uzorku NUTS2 regija. Važno je, pored analize signifikantnosti, također i naglasiti predznake procijenjenih koeficijenata, te istaknuti one varijable koje su statistički značajne. U ovom radu vodilo se statističkom značajnošću pri empirijskog razini signifikantnosti manjoj od 5 posto, ali je također spomenuto i koje su varijable statistički značajne i pri empirijskim razinama manjima od 10, odnosno od 1 posto. Rezultati dinamičkog panel modela pomoću AB (Arellano Bond) procjenitelja u dva koraka s uobičajenim standardnim pogreškama su dani u ispisu programa STATA, pri čemu je zavisna varijabla stopa rasta BDP-a (BDP Growth).

U nastavku je predstavljeno pet tablica zbog toga jer se za svaku novu analizu ostavilo zavisnu varijablu i sve nezavisne varijable osim indeksa specijaliziranosti netaknutima. Kako ih ima

pet, tako je odrađeno i pet različitih analiza gdje je u svakoj novoj mijenjan indeks specijalizacije. Kao što je prije spomenuto, korišten je AB procjenitelj u dva koraka. Razlog tome leži u činjenici što se analiza odrađena AB procjeniteljem u jednom koraku nije mogla testirati na autokorelaciju, a ta dijagnostika i govori o tome je li model kojeg koristimo ispravan ili ne.

Tablica 7: Panel analiza utjecaja gospodarske strukture regije s indeksom specijalizacije „A“ na gospodarski rast

Arellano-Bond dynamic panel-data estimation Number of obs = 581
Group variable: id Number of groups = 93
Time variable: year
Obs per group: min = 1
avg = 6.247312
max = 10
Number of instruments = 73 Wald chi2(11) = 1.50e+06
Prob > chi2 = 0.0000
Two-step results

GDP Growth	Coef.	Std. Err.	z	P>|z|	[95% Conf.	Interval]
GDP Growth						
L1.	**-.0119002**	**.0013367**	**-8.90**	**0.000**	**-.01452**	**-.0092804**
GDPgrowth pc	**.9819169**	**.0022602**	**434.43**	**0.000**	**.977487**	**.9863469**
Obrazovanje	**.0002516**	**.0000984**	**2.56**	**0.011**	**.0000588**	**.0004444**
RDgrowthpc	-.0000705	.0011127	-0.06	0.949	-.0022513	.0021103
RDgrowth	.0002862	.0009263	0.31	0.757	-.0015293	.0021016
RDGrowthps/pc	**.0018896**	**.0005512**	**3.43**	**0.001**	**.0008093**	**.0029698**
RDGrowthps	**-.0024503**	**.0004955**	**-4.94**	**0.000**	**-.0034215**	**-.0014791**
Brutoinvest.	**.0026075**	**.0010852**	**2.40**	**0.016**	**.0004806**	**.0047344**
Stanovništvo	**.0007781**	**.0000612**	**12.70**	**0.000**	**.000658**	**.0008981**
Investicije	.000915	.0014406	0.64	0.525	-.0019086	.0037386
Indeks „A“	.0078713	.0043206	1.82	0.068	-.0005968	.0163395
_cons	-.012996	.0045053	-2.88	0.004	-.0218263	-.0041658

Izvor: Izračun autora

Jednadžba modela može se ispisati na sljedeći način:

$GDP\ Growth_r$ = - 0.012996 – 0.0119002 $GDP\ Growth_{r,\ t-1}$ + 0.9819169**GDPgrowth pc* + 0.0002516**Obrazovanje* – 0.000705**RDgrowth per capita* + 0.0002862**RDGrowth* +

0.0018896**RDGrowth(ps) per capita* – 0.0024503**RDGrowth(ps)* + 0.0026075**Bruto investicije* + 0.0007781**Stanovništvo* + 0.000915**Investicije* + 0.0078713**Indeks „A“*

Prema procijenjenom modelu značajne varijable na razini signifikantnosti od 5% su: stopa rasta BDP-a iz prethodnog razdoblja (negativan utjecaj), rast BDP-a per capita (pozitivan utjecaj), Obrazovanje (pozitivan utjecaj), troškovi za R&D u poslovnom sektoru per capita (pozitivan utjecaj), troškovi za R&D u poslovnom sektoru (negativan utjecaj), bruto investicije (pozitivan utjecaj), stopa promjene broja stanovništva (pozitivan utjecaj). Statistički neznačajne varijable su: troškovi R&D per capita (negativan utjecaj), troškovi R&D (pozitivan utjecaj), investicije (pozitivan utjecaj), te indeks specijalizacije u A razredu djelatnosti (pozitivan utjecaj).

Da bi se testirala prikladnost modela proveli su se Sargan test i testovi autokorelacije.

Tablica 8: Sargan test i testovi autokorelacije analize utjecaja gospodarske strukture regije s indeksom specijalizacije „A“ na gospodarski rast

```
Sargan test of overidentifying restrictions
        H0: overidentifying restrictions are valid

        chi2(61)     =  71.43371
        Prob > chi2  =    0.1697

Arellano-Bond test for zero autocorrelation in first-differenced errors
  +----------------------+
  |Order |  z     Prob > z|
  |------+---------------|
  |   1  |-3.6836  0.0002 |
  |   2  | .78399  0.4330 |
  +----------------------+
   H0: no autocorrelation
```

Izvor: izračun autora

Sarganovim testom se testira nulta hipoteza prema kojoj se pretpostavlja valjanost instrumentalnih varijabli. U ovom slučaju testna veličina je hi-kvadrat vrijednost 71.43371, dok je pripadajuća p-vrijednost 0.1697. Kada je p-vrijednost veća od 0.05, odnosno od uobičajene razine signifikantnosti nulta hipoteza o valjanosti instrumentalnih varijabli se prihvaća. To znači da je model prikladan.

Testovi za autokorelaciju prvog i drugog reda pokazali su kako je vrijednost *m1* testa manja od uobičajene razine signifikantnosti od 0.005 zbog čega se nulta hipoteza odbacuje. No, budući da se među prvim diferencijama reziduala očekuje postojanje autokorelacije prvog reda, njezino se postojanje najčešće zanemaruje.

Naime, uz postojanje autokorelacije prvog reda među prvim diferencijama reziduala procjene parametara su konzistentne. No, ako postoji korelacija drugog reda među prvim diferencijama reziduala, procjene parametara su nekonzistentne.[27] U ovom slučaju, u *m2* testu, p vrijednost veća je od 0.05, te se prihvaća nulta hipoteza o nepostojanju autokorelacije drugog reda. Budući da se autokorelacija u prvom redu može zanemariti, izabrani model s pripadajućim varijablama je prikladan i valjan za statističku analizu.

Tablica 9: Panel analiza utjecaja gospodarske strukture regije s indeksom specijalizacije „B-E“ na gospodarski rast

[27] Škrabić Perić, B. (2015), Nastavni materijali iz kolegija „naliza vremenskih serija i panel podataka“. Ekonomski fakultet Split, Split.

```
Arellano-Bond dynamic panel-data estimation  Number of obs         =       581
Group variable: id                           Number of groups      =        93
Time variable: year
                                             Obs per group:    min =         1
                                                               avg =  6.247312
                                                               max =        10
Number of instruments =     73               Wald chi2(11)         = 981631.41
                                             Prob > chi2           =    0.0000
Two-step results
------------------------------------------------------------------------------
   GDP Growth|      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
   GDP Growth|
         L1. |  -.0111879   .0013815    -8.10   0.000    -.0138955   -.0084802
             |
GDPgrowth pc |   .9812778   .0022673   432.79   0.000      .976834    .9857217
Obrazovanje  |   .0003147   .0000967     3.25   0.001     .0001251    .0005043
RDgrowthpc   |  -.0002906   .0011166    -0.26   0.795     -.002479    .0018978
RDgrowth     |   .0005771   .0009776     0.59   0.555     -.001339    .0024931
RDGrowthps/pc|   .0023502    .000567     4.14   0.000     .0012388    .0034616
RDGrowthps   |  -.0028529   .0005154    -5.54   0.000     -.003863   -.0018428
Brutoinvest. |   .0028583   .0010569     2.70   0.007     .0007867    .0049299
Stanovništvo |   .0008246    .000056    14.73   0.000     .0007149    .0009343
Investicije  |   .0008157   .0014782     0.55   0.581    -.0020814    .0037129
Indeks „B-E" |  -.0492735   .0088963    -5.54   0.000    -.0667099   -.0318371
       _cons |   .0453008   .0094955     4.77   0.000       .02669    .0639117
```

Izvor: Izračun autora

Jednadžba modela može se ispisati na sljedeći način:

$GDP\ Growth_r$ = 0.0453008 – 0.0111879**GDP Growth*$_{r,\ t-1}$ + 0.9812778**GDPgrowth pc* + 0.0003147**Obrazovanje* – 0.0002906**RDgrowth per capita* + 0.0005771**RDGrowth* + 0.0023502**RDGrowth(ps) per capita* – 0.0028529**RDGrowth(ps)* + 0.0028583**Bruto investicije* + 0.0008246**Stanovništvo* + 0.0008157**Investicije* - 0.0492735**Indeks „B-E"*.

Prema procijenjenom modelu značajne varijable na razini signifikantnosti od 5% su: stopa rasta BDP-a iz prethodnog razdoblja (negativan utjecaj), rast BDP-a per capita (pozitivan utjecaj), obrazovanje (pozitivan utjecaj), troškovi za R&D u poslovnom sektoru per capita (pozitivan utjecaj), troškovi za R&D u poslovnom sektoru (negativan utjecaj), bruto investicije (pozitivan utjecaj), stopa promjene broja stanovništva (pozitivan utjecaj), te indeks specijalizacije u djelatnostima „B-E" razreda (negativan utjecaj).

Statistički neznačajne varijable su: troškovi R&D per capita (pozitivan utjecaj), troškovi R&D (negativan utjecaj), investicije (pozitivan utjecaj).

Tablica 10: Sargan test i testovi autokorelacije analize utjecaja gospodarske strukture regije s indeksom specijalizacije „B-E“ na gospodarski rast

```
Sargan test of overidentifying restrictions
        H0: overidentifying restrictions are valid

        chi2(61)     =  67.11715
        Prob > chi2  =    0.2755

Arellano-Bond test for zero autocorrelation in first-differenced errors
  +----------------------+
  |Order |  z     Prob > z|
  |------+---------------|
  |   1  |-3.7399  0.0002 |
  |   2  | .83845  0.4018 |
  +----------------------+
   H0: no autocorrelation
```

Izvor: izračun autora

Sargan test i testovi autokorelacije pokazali su, kao i prethodnom slučaju, kako je izabrani model s pripadajućim varijablama prikladan i valjan za statističku analizu.

Tablica 11: Panel analiza utjecaja gospodarske strukture regije s indeksom specijalizacije „F“ na gospodarski rast

```
Arellano-Bond dynamic panel-data estimation  Number of obs         =       581
Group variable: id                           Number of groups      =        93
Time variable: year
                                             Obs per group:    min =         1
                                                               avg =  6.247312
                                                               max =        10
Number of instruments =     73               Wald chi2(11)         =  1.27e+06
                                             Prob > chi2           =    0.0000
Two-step results
------------------------------------------------------------------------------
   GDP Growth|      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
   GDP Growth|
         L1. |  -.0113205   .0015608    -7.25   0.000    -.0143797   -.0082614
             |
GDPgrowth pc |   .9799034    .002168   451.98   0.000     .9756542    .9841527
Obrazovanje  |   .0002235   .0000985     2.27   0.023     .0000304    .0004167
RDgrowthpc   |   .0004595   .0011629     0.40   0.693    -.0018198    .0027388
RDgrowth     |  -.0002191   .0009854    -0.22   0.824    -.0021503    .0017122
RDGrowthps/pc|   .0025275    .000554     4.56   0.000     .0014416    .0036134
RDGrowthps   |  -.0030945   .0005243    -5.90   0.000    -.0041221   -.0020669
Brutoinvest. |   .0027027    .001061     2.55   0.011     .0006232    .0047822
Stanovništvo |   .0007543   .0000629    11.99   0.000     .0006309    .0008776
Investicije  |   .0018086   .0013857     1.31   0.192    -.0009075    .0045246
Indeks „F"   |   -.012692   .0042892    -2.96   0.003    -.0210986   -.0042854
       _cons |   .0098355   .0055856     1.76   0.078     -.001112     .020783
```

Izvor: Izračun autora

Jednadžba modela može se ispisati na sljedeći način:

$GDP\ Growth_r$ = 0.098355 – 0.0113205**GDP Growth*$_{r,\ t-1}$ + 0.9799034**GDPgrowth pc* + 0.0002235**Obrazovanje* + 0.0004595**RDgrowth per capita* - 0.0002191**RDGrowth* + 0.0025275**RDGrowth(ps) per capita* – 0.000030945**RDGrowth(ps)* + 0.0027027**Bruto investicije* + 0.0007543**Stanovništvo* + 0.0018086**Investicije* - 0.012692**Indeks „F"*.

Prema procijenjenom modelu značajne varijable na razini signifikantnosti od 5% su: stopa rasta BDP-a iz prethodnog razdoblja (negativan utjecaj), rast BDP-a per capita (pozitivan utjecaj), obrazovanje (pozitivan utjecaj), troškovi za R&D u poslovnom sektoru per capita (pozitivan utjecaj), troškovi za R&D u poslovnom sektoru (negativan utjecaj), bruto investicije (pozitivan utjecaj), stopa promjene broja stanovništva (pozitivan utjecaj), te indeks specijalizacije u djelatnostima „B-E" razreda (negativan utjecaj).

Statistički neznačajne varijable su: troškovi R&D per capita (pozitivan utjecaj), troškovi R&D (negativan utjecaj), investicije (pozitivan utjecaj).

Tablica 12: Sargan test i testovi autokorelacije analize utjecaja gospodarske strukture regije s indeksom specijalizacije „F“ na gospodarski rast

```
Sargan test of overidentifying restrictions
        H0: overidentifying restrictions are valid

        chi2(61)     =  71.80588
        Prob > chi2  =    0.1622

Arellano-Bond test for zero autocorrelation in first-differenced errors
  +----------------------+
  |Order |  z     Prob > z|
  |------+----------------|
  |   1  |-3.7134  0.0002 |
  |   2  | .76053  0.4469 |
  +----------------------+
   H0: no autocorrelation
```

Izvor: Izračun autora

Sargan test i testovi autokorelacije pokazali su, kao i prethodnom slučaju, kako je izabrani model s pripadajućim varijablama prikladan i valjan za statističku analizu.

Tablica 13: Panel analiza utjecaja gospodarske strukture regije s indeksom specijalizacije „G-N“ na gospodarski rast

Arellano-Bond dynamic panel-data estimation — Number of obs = 455
Group variable: id — Number of groups = 87
Time variable: year
Obs per group: min = 1
avg = 5.229885
max = 10
Number of instruments = 77 — Wald chi2(11) = 7.80e+06
Prob > chi2 = 0.0000
Two-step results

GDP Growth	Coef.	Std. Err.	z	P>|z|	[95% Conf.	Interval]
GDP Growth						
L1.	**-.0139314**	**.0014048**	**-9.92**	**0.000**	**-.0166847**	**-.0111781**
GDPgrowth pc	**.9799266**	**.001473**	**665.26**	**0.000**	**.9770395**	**.9828136**
Obrazovanje	**.0005294**	**.0000617**	**8.58**	**0.000**	**.0004085**	**.0006504**
RDgrowthpc	-.0013801	.001008	-1.37	0.171	-.0033557	.0005955
RDgrowth	.0014681	.0008904	1.65	0.099	-.0002771	.0032133
RDGrowthps/pc	**.0021548**	**.0005377**	**4.01**	**0.000**	**.001101**	**.0032086**
RDGrowthps	**-.0026409**	**.0004572**	**-5.78**	**0.000**	**-.0035371**	**-.0017447**
Brutoinvest.	**.0048713**	**.0007107**	**6.85**	**0.000**	**.0034784**	**.0062642**
Stanovništvo	**.0006278**	**.0000417**	**15.06**	**0.000**	**.0005461**	**.0007095**
Investicije	-.0009382	.0009757	-0.96	0.336	-.0028506	.0009742
Indeks „G-N“	**.0500147**	**.0065625**	**7.62**	**0.000**	**.0371525**	**.0628769**
_cons	-.0575502	.0072105	-7.98	0.000	-.0716826	-.0434178

Izvor: Izračun autora

Jednadžba modela može se ispisati na sljedeći način:

$GDP\ Growth_r$ = - 0.575502 – 0.0139314**GDP Growth*$_{r,\ t-1}$ + 0.9799266**GDPgrowth pc* + 0.0005294**Obrazovanje* - 0.0013801**RDgrowth per capita* + 0.0014681**RDGrowth* + 0.0021548**RDGrowth(ps) per capita* – 0.0026409**RDGrowth(ps)* + 0.0048713**Bruto investicije* + 0.0006278**Stanovništvo* - 0.0009382 **Investicije* + 0.500147**Indeks „F“*.

Prema procijenjenom modelu značajne varijable na razini signifikantnosti od 5% su: stopa rasta BDP-a iz prethodnog razdoblja (negativan utjecaj), rast BDP-a per capita (pozitivan utjecaj), obrazovanje (pozitivan utjecaj), troškovi za R&D u poslovnom sektoru per capita (pozitivan utjecaj), troškovi za R&D u poslovnom sektoru (negativan utjecaj), bruto investicije (pozitivan

utjecaj), stopa promjene broja stanovništva (pozitivan utjecaj), te indeks specijalizacije u djelatnostima „G-N“ razreda (pozitivan utjecaj). Statistički neznačajne varijable su: troškovi R&D per capita (negativan utjecaj), troškovi R&D (pozitivan utjecaj), investicije (negativan utjecaj).

Tablica 14: Sargan test i testovi autokorelacije analize utjecaja gospodarske strukture regije s indeksom specijalizacije „G-N“ na gospodarski rast

```
Sargan test of overidentifying restrictions

 H0: overidentifying restrictions are valid

        chi2(65)     =  67.16439
        Prob > chi2  =    0.4028

Arellano-Bond test for zero autocorrelation in first-differenced errors
  +------------------------+
  |Order |  z     Prob > z|
  |------+----------------|
  |   1  |-3.4582  0.0005 |
  |   2  | .77085  0.4408 |
  +------------------------+
   H0: no autocorrelation
```

Izvor: Izračun autora

Sargan test i testovi autokorelacije pokazali su, kao i prethodnom slučaju, kako je izabrani model s pripadajućim varijablama prikladan i valjan za statističku analizu.

Tablica 15: Panel analiza utjecaja gospodarske strukture regije s indeksom specijalizacije „O-U“ na gospodarski rast

Arellano-Bond dynamic panel-data estimation Number of obs = 455
Group variable: id Number of groups = 87
Time variable: year
Obs per group: min = 1
avg = 5.229885
max = 10
Number of instruments = 77 Wald chi2(11) = 4.66e+06
Prob > chi2 = 0.0000
Two-step results

GDP Growth	Coef.	Std. Err.	z	P>|z|	[95% Conf.	Interval]
GDP Growth |						
L1.	**-.0133082**	**.0013067**	**-10.18**	**0.000**	**-.0158692**	**-.0107472**
GDPgrowth pc	**.9812476**	**.0014822**	**662.00**	**0.000**	**.9783425**	**.9841528**
Obrazovanje	**.0005004**	**.0000657**	**7.62**	**0.000**	**.0003717**	**.0006292**
RDgrowthpc	-.0011512	.001076	-1.07	0.285	-.0032602	.0009579
RDgrowth	.0014037	.0008978	1.56	0.118	-.0003559	.0031633
RDGrowthps/pc	**.0019738**	**.0006169**	**3.20**	**0.001**	**.0007646**	**.0031829**
RDGrowthps	**-.0025269**	**.0005088**	**-4.97**	**0.000**	**-.003524**	**-.0015297**
Brutoinvest.	**.0050128**	**.0006508**	**7.70**	**0.000**	**.0037373**	**.0062883**
Stanovništvo	**.0005858**	**.000037**	**15.81**	**0.000**	**.0005132**	**.0006584**
Investicije	-.0016777	.0009746	-1.72	0.085	-.003588	.0002325
Indeks „O-U“	**-.0297568**	**.0042641**	**-6.98**	**0.000**	**-.0381143**	**-.0213994**
_cons	.0227811	.0047905	4.76	0.000	.0133918	.0321703

Izvor: Izračun autora

Jednadžba modela može se ispisati na sljedeći način:

$GDP\ Growth_r$ = 0.227811 – 0.0133082**GDP Growth*$_{r,\ t-1}$ + 0.9812479**GDPgrowth pc* + 0.0005004**Obrazovanje* - 0.0011512**RDgrowth per capita* + 0.0014037**RDGrowth* + 0.0019738**RDGrowth(ps) per capita* – 0.0025269**RDGrowth(ps)* + 0.0050128**Bruto investicije* + 0.0005858**Stanovništvo* - 0.0016777 **Investicije* - 0.297568**Indeks „F“*.

Prema procijenjenom modelu značajne varijable na razini signifikantnosti od 5% su: stopa rasta BDP-a iz prethodnog razdoblja (negativan utjecaj), rast BDP-a per capita (pozitivan utjecaj), obrazovanje (pozitivan utjecaj), troškovi za R&D u poslovnom sektoru per capita (pozitivan utjecaj), troškovi za R&D u poslovnom sektoru (negativan utjecaj), bruto investicije (pozitivan

utjecaj), stopa promjene broja stanovništva (pozitivan utjecaj), te indeks specijalizacije u djelatnostima „G-N“ razreda (pozitivan utjecaj).

Statistički neznačajne varijable su: troškovi R&D per capita (negativan utjecaj), troškovi R&D (pozitivan utjecaj), investicije (negativan utjecaj).

Tablica 16: Sargan test i testovi autokorelacije analize utjecaja gospodarske strukture regije s indeksom specijalizacije „O-U“ na gospodarski rast

```
Sargan test of overidentifying restrictions
 H0: overidentifying restrictions are valid

         chi2(65)     =  66.30726
         Prob > chi2  =    0.4316

 Arellano-Bond test for zero autocorrelation in first-differenced errors
   +----------------------+
   |Order |  z     Prob > z|
   |------+---------------|
   |   1  | -3.207  0.0013 |
   |   2  | .73366  0.4632 |
   +----------------------+
    H0: no autocorrelation
```

Izvor: Izračun autora

Sargan test i testovi autokorelacije pokazali su, kao i prethodnom slučaju, kako je izabrani model s pripadajućim varijablama prikladan i valjan za statističku analizu.

Analiza odnosa gospodarske strukture regija Europske unije i njihovog gospodarskog rasta pokazala je sljedeće.

- Indeks specijalizacije razreda djelatnosti „**A**“ pokazao se statistički neznačajan na razinama signifikantnosti od 1% i 5%. No, na razini od 10 % signifikantnosti pokazao se statistički značajnim.
- Ostala četiri indeksa specijalizacije koji obuhvaćaju razrede djelatnosti **„B-E“, „F“, „G-N“, „O-U“** pokazala su se statistički značajna na razinama signifikantnosti od 5% i 10%. Pored toga, indeksi „**B-E**“, „**G-N**“, te „**O-U**“ pokazali su se statistički značajnima i pri razini signifikantnosti od 1%.

Samim time potvrđena je druga pomoćna hipoteza (**PH2**) koja glasi: Gospodarska struktura regija Europske unije determinira gospodarski rast promatranih regija.

Kao što je prije spomenuto, analiza se provela i na panel modelu AB procjenitelja s izmjenjenim varijablama (analiza **2b**). Ovoga puta za zavisnu varijablu smo stavili rast BDP-a per capita, dok smo u grupu nezavisnih varijabli uvrstili rast BDP-a.

U ovom slučaju su se statistički značajnima pokazali indeksi u razredima djelatnosti **B-E“, „F“, „G-N“, „O-U“** na razinama signifikantnosti od 5% i 10%. Pored toga, kao i u prethodnom slučaju, indeksi „**B-E**“, „**G-N**“, te „**O-U**“ pokazali su se statistički značajnima i pri razini signifikantnosti od 1%. Sa analizom **2b** dodatno je potvrđena druga pomoćna hipoteza (**PH2**).

4.4.3. Analiza odnosa gospodarske strukture regija EU i njihove ekonomske respondibilnosti

Zavisna varijabla u ovoj, završnoj, analizi je Martinov indeks osjetljivosti koji označava ekonomsku respondibilnost, a u nezavisne varijable uvršteni su indeksi specijalizacije.

Tablica 17: Panel analiza utjecaja gospodarske strukture regija na njenu ekonomsku respondibilnost

```
Arellano-Bond dynamic panel-data estimation  Number of obs         =      1243
Group variable: id                           Number of groups      =       195
Time variable: year
                                             Obs per group:    min =         1
                                                               avg =  6.374359
                                                               max =        11
Number of instruments =     72               Wald chi2(6)          =   1991.50
                                             Prob > chi2           =    0.0000
Two-step results
------------------------------------------------------------------------------
Martin indeks|      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
Martin indeks|
         L1. |  -.0886739   .0028852   -30.73   0.000    -.0943289    -.083019
             |
Indeks „A"   |  -29.35598   2.893043   -10.15   0.000    -35.02624   -23.68572
Indeks „B-E" |  -186.1606   9.177692   -20.28   0.000    -204.1485   -168.1726
Indeks „F"   |  -63.22119   4.328174   -14.61   0.000    -71.70425   -54.73812
Indeks „G-N" |  -406.4852   12.50385   -32.51   0.000    -430.9923   -381.9781
Indeks „O-U" |  -307.6501   8.762593   -35.11   0.000    -324.8245   -290.4757
       _cons |    990.638   27.24687    36.36   0.000     937.2351    1044.041
```

Izvor:Izračun autora

Jednadžba modela može se ispisati na sljedeći način:

Y_{rt} = 990.638 - 0.0886739*Y_{rt-1} -29.35598**Indeks „A“* – 186.1606**Indeks „B-E“* – 63.2219**Indeks „F“* – 406.4852**Indeks „G-N“* -307.6501**Indeks „O-U“*

Razlozi velikih koeficijenata leže u tome što je indeks respondibilnosti (Martinov indeks) sadrži velike outliere, te je razlika između njegovih minimuma i maksimuma iznimno velika u odnosu na minimume i maksimume indeksa specijalizacije. No, kao što je u uvodnom dijelu rada rečeno, mnogi autori specijalizaciju ne vide kao pozitivan trend što se tiče jačanja ekonomske respondibilnosti (naprotiv, za jačanje ekonomske respondibilnosti preporučuju ekonomsku diversificiranost)

Upravo je to pokazala i ova analiza. Svi indeksi su statistički značajni na svim razinama signifikantnosti (1%,5%,10%) i svi imaju negativan utjecaj. Što znači da se porastom respondibilnosti određene regije smanjuje njezina specijaliziranost.

Tablica 18: Sargan test i testovi autokorelacije analize utjecaja gospodarske strukture regije na njenu ekonomsku respondibilnost

```
Sargan test of overidentifying restrictions
        H0: overidentifying restrictions are valid

        chi2(65)     =  64.05168
        Prob > chi2  =    0.5100

Arellano-Bond test for zero autocorrelation in first-differenced errors
  +----------------------+
  |Order |  z     Prob > z|
  |------+----------------|
  |   1  |-1.8732  0.0610 |
  |   2  |-1.2365  0.2163 |
  +----------------------+
  H0: no autocorrelation
```

Izvor: Izračun autora

Model, kao i njegovi instrumenti, su reprezentativni, valjani, i prikladni što se vidi iz rezultata Sargan testa, kao i iz testa autokorelacija od kojih su oba (*m1* i *m2*) potvrdila nultu hipotezu o nepostojanju autokorelacije među prvim diferencijama reziduala procjene parametara.

Vrijednosti p parametara manje su od 0.05, te su potvrdile glavnu hipotezu (**GH**) koja glasi: Gospodarska struktura regije signifikantno utječe na njenu ekonomsku respondibilnost.

5. ZAKLJUČAK

U zadnjih nekoliko desetljeća povećala se nesigurnost globalnog gospodarstva, a koja se ogleda u pojavi financijskih kriza i visokih troškova u razinama proizvodnje, fluktuaciji u broju

zaposlenih, a koje pak vodi do smanjenja produktivnosti što rezultira neefikasnim trošenjem sredstava od strane državnih, regionalnih i lokalnih vlasti. Najveće usporavanje agregatne ekonomske aktivnosti Europske unije od vremena Velike depresije zabilježeno je s ekonomskom krizom koja je počela 2008. godine. Došlo je do zastoja u dugoročnim trendovima konvergencije BDP-a, i do značajnog pada stope zaposlenosti u državama članicama EU.

Upravo u vrijeme pojave sve veće financijske nesigurnosti, dakle zadnjih nekoliko desetaka godina, pomaknuo se fokus s promatranja država na analizu gospodarstava regija. Europska unija uspostavila je relativno efikasan sistem nomenklature i klasifikacije regija u svojim državama članicama na NUTS razinama. Time se povećao uzorak, a i rezultati postaju donekle precizniji. Problem koji se javlja pri tome, barem što se znanstvenih analiza tiče, jest dostupnost podataka.

Utjecaj kriza, odnosno eksternih šokova, prema Martinu (2012) premjestio se s državne na regionalnu razinu. On smatra kako pitanje regionalne osjetljivosti na eksterne šokove nije nikada bilo aktualnije. Regionalna politika EU zanimljiva je ne samo zbog novog pogleda i novih aspekata istraživanja, već i zbog toga što predstavlja pokušaj da se konvergencijom novih i starih članica uklone dispariteti u razvoju.

Propadanje pojedinih regionalnih gospodarstava uzrokovano recesijom iz 2008. Godine vratilo je u fokus regije, njihovu ekonomiju, kao i način kako bi mogle poboljšati svoju samodostatnost, otpornost, održivost. Jedan od načina mjerenja ove tri karakteristike jest i Martinov indeks osjetljivosti kojeg smo u radu iskoristili kao mjeru ekonomske repsondibilnosti i koju smo stavili u zavisni položaj u odnosu na gospodarsku strukturu regije.

Gospodarsku strukturu regije okarakterizirali smo s nekoliko faktora, pri čemu se pet analiza razlikovalo samo u indeksu specijalizacije kojeg smo tako postavili kao glavnu determinantu gospodarske strukture.

Kao glavnu mjeru računanja Martinovog indeksa, odnosno mjere ekonomske respondibilnosti kao i indeksa specijalizacije koristili smo razinu zaposlenosti. No, isti se postupak može napraviti i koristeći GVA, odnosno bruto dodanu vrijednost po djelatnostima. Samim time bi se eventualno eliminirali potencijalni nedostaci koji se javljaju prilikom izračuna indeksa specijalizacije gdje, primjerice, određeni prosjek jedne regije je tri puta veći od državnog i zbog čega je ta regija specijalizirana u toj djelatnosti, iako su u istoj regiji postoci zaposlenih u drugim

djelatnostima veći. Zbog toga se preporučuje da se izvrši i ovakav tip analize, u kojem će se koristiti GVA umjesto razine zaposlenosti te da se rezultati i jedne i druge analize usporede.

Analiza iz ovog rada je pokazala kako specijaliziranost pojedinih regija ne samo da utječe na njihov gospodarski rast već ujedno i signifikantno utječe na njenu ekonomsku respondibilnost i to u negativnom smislu. To je i u skladu s aktualnom literaturom koja nam kaže kako veća specijaliziranost regije znači da je ta ista regija podložnija ekonomskim šokovima, te da njezin oporavk teče sporije od manje specijaliziranih, odnosno od regija s manje diversificiranim gospodarstvima.

6. POPIS LITERATURE

1. „Analysis of the main factors of regional growth: An in-depth study of the best and worst performing regions“, (2012), A final report for the European Commission, Directorate General Regional Policy, Executive Summary, str. 9, Cambridge Econometrics.

2. Anić, V. (1998), "Rječnik hrvatskoga jezika", Novi Liber, Zagreb.

3. Anić, V., Goldstein, I. (2000), "Rječnik stranih riječi", Novi Liber, Zagreb.

4. Babić, M. (2011), „Ekonomija: uvod u analizu i politiku“, drugo dorađeno izdanje, Znanje d.o.o., Zagreb.

5. Briguglio, L. (2007), „Building the economic resillience of small states“, presentation prepared for the 2007 Small States Forum The World Bank, Washington.

6. Briguglio, L. (2004), „Economic vulnerability and resilience: Concepts and measures“ in: „Briguglio, L., Kisanga, E., J. „Economic Vulnerability and Resilience of Small States“, Islands and Small states Institute of the Universtiy of Malta, London, Commonwealth Secretariat.

7. Briguglio, L., Cordina, G. Farrugia, and Stephanie Vella, S. (2009), „Economic Vulnerability and Resilience: Concept and Measurements“, Oxford Development studies, 37:3, pp 229-247.

8. Caldera Sanchez, A., Rasmussen, M. and Röhn O. (2015), „Economic Resilience: What role for policies?“, OECD Economics Department Working Papers, No. 1251.

9. Cellini, R.,Torrisi, G. (2014), Regional Resilience in Italy: A Very Long-Run Analysis“, Regional Studies, 48:11, str. 1779-1796.

10. Čorić, B., and Perović, M.L. (2013), „Makroekonomija: Teorija i politika“, Sveučilište u Splitu, Ekonomski fakultet, Split.

11. Dissart J.C. (2003), „Regional Economic Diversity and Regional economic Stability: Research Results and Agenda“, International Regional Science Review, vol. 26.

12. Domazlicky, B. (1980), „Regional business cycles: A survey“, Regional Science Perspectives, Vol. 10, str. 15-34.

13. Dory T. (2008), „RTD policy approaches in different types of european regions“, working paper, Institute for Prospective Technological Studies.

14. Duval, R., Elmeskov, J. and Vogel L. (2007), „Structural policies and economic resilience to shocks“, OECD Economics Department Working papers No. 567.

15. Ersoy, A., Taylor M. (2012), „Understanding Dynamics of Local and Regional Economic Development in Emerging Countries“, Economic Research, Vol 25, No. 4, pp. 1079-1088.

16. Fagberg, J., Verspagen, B., Caniëls (1997), „Technology, Growth and Unemployment across European Regions“, Regional Studies, vol. 31.5, pp. 457-466.

17. Filipović, R. et al. (1992), "Englesko-hrvatski rječnik", 10. izdanje, Školska Knjiga, Zagreb.

18. Fingleton, B, Garretsen, H i Martin, R.(2012), „Recessionary shocks and regional employment: evidence on th resilience of U.K. regions“, Regional Science No. 52, str. 109-133.

19. Grdešić, M. (2013), „Inovativne ili bogate regije? Prostorna ekonometrijska analiza regija Europske unije“, Institut za društvena istraživanja u Zagrebu, Zagreb.

20. Grupa autora (2015), „A Framework for Measuring County Economic Resilience: An Application to West Virginia“, working paper No. 3, Regional Research Institute.

21. Hermansen, M, Röhn, O. (2015), „Economic resilience: The usefulness of early warning indicators in OECD countries“, OECD Economics Department Working Paper, No. 1250.

22. Hill et al. (2011), „Economic Shocks and Regional EconomicResilience“, working paper, Institute of Govermental Studies, Sveučilište u Kaliforniji.

23. Jurković, P., Luković, F., Pribičević, Đ. i Ravlić, S. (1995), „Poslovni rječnik“, Masmedia, Zagreb.

24. Klaić, B. (2007), „Rječnik stranih riječi“, Školska knjiga d.d., Zagreb.

25. Martin R. (2011), „Regional economic resilience, hysteresis and recessionary shocks“, Journal of Economic Geography, str. 1-32.

26. Martin, R. et al. (2013), „On the notion on regional economic resilience: Conceptualisation, and explanation“, Journal of Economic Geography

27. Ramlogan, R., and Metcalfe, J.S. (2006), „Restless capitalism: A complexity perspective on modern capitalist theories“, in Garnsey, E., and McGlade, J., „Complexity and Co-Evolution: Continuity and Change in Socio-Economic Systems“, pp. 115-146.

28. Rhön et al. (2015), „Economic Resilience: A new set of vulnerability indicators for OECD countries“, OECD Economics Department Working Papers, No. 1249, OECD Publishing, Paris

29. Sensier M., Artis, M. (2016), „The Resilience of Employment in Wales: Through Recession and into Recovery“, Regional Studies, 50:4, str. 586 – 599.

30. Sensier, M., Healy, A., Bristow, G. (2014), „Measuring European Regional Economic Resilience: operationalising a complex concept“, RSA Winter Conference, 27 November 2014, London .

31. Simmie, J. and Martin, R. (2010), „The economic resilience of regions: Towards an evolutionary approach“, Cambridge Journal of Regions, Economy and Society, Vol. 3, pp. 27-43.

32. Territorial Observation No. 12 (2014), „Territorial Dynamics in Europe: Economic Crisis and the Resilience of Regions“.

33. Z.Goschin, D. Luminita Constantin, M.Roman, B. Vasile Ileanu (2009), „Specialisation And Concentration Patterns In The Romanian Economy“, Journal Of Applied Quantitative Methods, Vol.4, No.1, str. 95-111.

7. POPIS TABLICA

Tablica 1: Tabelarni prikaz karakteristika regija na sve tri NUTS razine (str.19)

Tablica 2: Popis regija uključenih u analizu (str.20-21)

Tablica 3: Grupiranje djelatnosti u sklopu NACE nomenklature (str.26)

Tablica 4: Deskriptivna statistika indeksa osjetljivosti (str.31)

Tablica 5: Kolmogorov-Smirnov test distribucije indeksa osjetljivosti (str.31)

Tablica 6: Kruskal-Wallis test (str.32)

Tablica 7: Panel analiza utjecaja gospodarske strukture regije s indeksom specijalizacije „A“ na gospodarski rast (str.33)

Tablica 8: Sargan test i testovi autokorelacije analize utjecaja gospodarske strukture regije s indeksom specijalizacije „A“ na gospodarski rast (str.34)

Tablica 9: Panel analiza utjecaja gospodarske strukture regije s indeksom specijalizacije „B-E“ na gospodarski rast (str.36)

Tablica 10: Sargan test i testovi autokorelacije analize utjecaja gospodarske strukture regije s indeksom specijalizacije „B-E“ na gospodarski rast (str.37)

Tablica 11: Panel analiza utjecaja gospodarske strukture regije s indeksom specijalizacije „F“ na gospodarski rast (str.38)

Tablica 12: Sargan test i testovi autokorelacije analize utjecaja gospodarske strukture regije s indeksom specijalizacije „F“ na gospodarski rast (str.39)

Tablica 13: Panel analiza utjecaja gospodarske strukture regije s indeksom specijalizacije „G-N“ na gospodarski rast (str.40)

Tablica 14: Sargan test i testovi autokorelacije analize utjecaja gospodarske strukture regije s indeksom specijalizacije „G-N“ na gospodarski rast (str. 41)

Tablica 15: Panel analiza utjecaja gospodarske strukture regije s indeksom specijalizacije „O-U“ na gospodarski rast (str.42)

Tablica 16: Sargan test i testovi autokorelacije analize utjecaja gospodarske strukture regije s indeksom specijalizacije „O-U“ na gospodarski rast (str.43)

Tablica 17: Panel analiza utjecaja gospodarske strukture regija na njenu ekonomsku respondibilnost (str.45)

Tablica 18: Sargan test i testovi autokorelacije analize utjecaja gospodarske strukture regije na njenu ekonomsku respondibilnost (str.46)