PANEL ANALIZA ZNAČAJA VISOKOG OBRAZOVANJA U ZEMLJAMA SREDNJE I ISTOČNE EUROPE

Mamić, Hrvoje

Master's thesis / Diplomski rad

2015

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:124:379851

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

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

PANEL ANALIZA ZNAČAJA VISOKOG OBRAZOVANJA U ZEMLJAMA SREDNJE I ISTOČNE EUROPE

Mentor:

Doc. dr. sc. Blanka Škrabić Perić

Student:

Hrvoje Mamić

Split, listopad, 2015.

SADRŽAJ

1. UVOD 3

1.1 Problem istraživanja 3

1.2 Predmet istraživanja 6

1.3 Hipoteze 6

1.4 Ciljevi istraživanja 8

1.5 Metode istraživanja 8

1.6 Doprinos istraživanja 9

1.7 Struktura rada 9

2. OBRAZOVNI SUSTAVI ZEMALJA SREDNJE I ISTOČNE EUROPE ……...10

2.1 Teorijske odrednice obrazovnih sustava zemalja srednje i istočne Europe..... 10

2.2 Stanje u obrazovnim sustavima za vrijeme vladavine režima 13

2.3 Obrazovni sustavi nakon raspada režima 14

3. ZNAČAJ VISOKOG OBRAZOVANJA U ZEMLJAMA SREDNJE I ISTOČNE EUROPE 17

3.1 Teorijski aspekti utjecaja obrazovanja na ekonomskog rasta 17

3.2 Pregled dosadašnjih empirijskih istraživanja značaja obrazovanja 19

3.3 Pregled empirijskih istraživanja odnosa između visokog obrazovanja i ekonomskog rasta u zemljama srednje i istočne Europe 23

4. ANALIZA PANEL PODATAKA..... 25

4.1 Osnovne karakteristike panel analize..... 25

4.2 Statički panel modeli 26

4.2.1 Združeni panel model..... 26

4.2.2 Model između jedinica promatranja..... 28

4.2.3 Model s fiksnim efektom..... 28

4.2.4 Model s slučajnim efektom 30

4.2.5 Usporedba modela..... 33

4.3 Dinamički panel modeli 33

5. EMPIRIJSKA ANALIZA I REZULTATI **36**

5.1 Definiranje uzorka **36**

5.2 Oblikovanje ekonomskog modela **38**

5.3 Deskriptivna statistika **42**

5.4 Testiranje ekonomskog modela **43**

5.5 Analiza rezultata **56**

6. ZAKLJUČAK **58**

SAŽETAK **61**

SUMMARY **62**

LITERATURA **63**

POPIS TABLICA **69**

1. UVOD

1.1 Problem istraživanja

Obrazovna je djelatnost predmetom istraživanja analitičkih, normativnih i empirijskih disciplina koje tvore obrazovni sustav znanja o edukaciji. Problematika obrazovnih sustava istražuje se uglavnom multidisciplinarno, tj. parcijalno, sa stajališta različitih znanosti. Po funkcionalističkoj interpretaciji, do promjena u obrazovanju dolazi zbog promjena obrazovnih potreba koje su uvjetovane gospodarskim, političkim i kulturnim promjenama. Prema postulatima ravnotežne paradigme, obrazovni se sustav, kao sastavni dio šireg društvenog sustava, programski, organizacijski i institucionalno prilagođava tim promjenama. Na taj način obrazovanje prinosi integraciji i boljem funkcioniranju društva kao cjeline te porastu kvalitete ljudskog kapitala o kojemu ovisi razvojni potencijal zajednice (Pastuović, 1996). Unutar ovog rada istražit će se utjecaji visokog obrazovanja te njihov značaj koji imaju u ekonomskom rastu država u zemljama srednje i istočne Europe. Zemlje srednje i istočne Europe formirale su se iz zemalja koje su desetljećima bile pod autoritativnom kontrolom komunizma te državnog sustava. Obrazovni sustavi u ovim državama bili su usklađeni s centraliziranom birokracijom ekonomskog planiranja koja je potražnju za obrazovanjem određivala na temelju predviđanja te učinaka uslužnih djelatnosti. Kroz ovo razdoblje, ovakve obrazovne sustave karakterizirala su postignuća na području pismenosti te rodni paritet. Nakon pada komunizma u kasnim 80-im odnosno ranim 90-im godinama 20. stoljeća obrazovna infrastruktura je suočena s značajnim izazovima u smislu održavanja kvalitete, važnosti i pristupačnosti u vrijeme pada državne financijske potpore, promjenjive gospodarske klime te lošijeg stanja fizičkih resursa. Podaci o kretanjima u regiji pokazuju da se razine obrazovnih postignuća smanjuju te sužavaju u segmentima populacije koja ulazi u tercijarnu razinu obrazovanja. Ovo dokazuje kako se smanjuju te napuštaju politike i prakse koje su nekoć promicale jednake mogućnosti pristupa visokom obrazovanju. Cerych (1995 i 1999) u svojim istraživanjima promatra reforme u zemljama srednje i istočne Europe te definira četiri prijelomne točke u obrazovanju, i to redom, depolitizaciju obrazovanja, prekidanje državnog monopola u obrazovanju, pravo izbora obrazovnog puta te decentralizirano upravljanje i administraciju nad obrazovnim sustavom. U svojim radovima također identificira „nasljedstvo“ komunističkog režima kao jedan od glavnih faktora koji je utjecao na težu implementaciju i provedbu reformi obrazovanja u razdoblju tranzicije. Noviji radovi su pokušali u vezu dovesti visoko obrazovanje te ekonomski rast.

Holmes (2013) u svom radu istražuje utjecaje visokog obrazovanja na ekonomski rast putem tri kanala: akumulacija proizvodnih znanja i sposobnosti, generiranje novih znanja kroz inovacije te brže usvajanje postojećih suvremenih tehnologija. Nadalje, u model je uvrstio uključenost populacije u primarno, sekundarno i tercijarno obrazovanje te promatrao utjecaje na ekonomski rast i procjenjivao konvergenciju za klasični Solowljev model koji nije proširen za uključivanje ljudskog kapitala. Rezultat pokazuje kako su teorijske pretpostavke statistički značajnije kada je uvršten omjer upisanih u primarno, sekundarno i tercijarno obrazovanje. Korištenje Mankiw, Romer i Weil modela[1] uz uključenost samo sekundarnog obrazovanja ima snažan i značajan utjecaj pokazatelja na uvjetno stabilno stanje. Konačno, u nastavku je u razmatranje uzeta uključenost u sve tri razine obrazovanja. Rezultat pokazuje kako ni uključenost u primarno ni u tercijarno obrazovanje nemaju nikakav značajan utjecaj na rast u ovom modelu.

Istraživanja o značaju obrazovanja se mogu klasificirati u više skupina prema odnosima koje promatraju. Barro i Lee (1993), Barro i Sala-i-Martin (2004), Chatterji (1998), Romer (1990) koriste regresiju baziranu na komparativnim bazama podataka iz nekoliko desetaka razvijenih zemalja i zemalja u razvoju. Ove studije su pokušale objasniti povezanosti između obrazovanja i ekonomskog učinka direktnim putem, odnosno regresijskim indikatorima obrazovanja. Barro (1991) otkriva kako omjer upisanih u primarno i sekundarno obrazovanje predviđa veći rast. Mankiw, Romer i Weil (1992) zaključuju kako porast od 10% unutar omjera upisanih u sekundarno obrazovanje povećava rast za 2.2%. Istovremeno Levine i Renelt (1992) saznaju kako utjecaji omjera upisanih u primarno i sekundarno obrazovanje nisu robusni korištenjem različitih razdoblja. Nedavno istraživanje Baldaccia, Clementsa, Gupta i Cuia (2008) također pokazuje kako povećani omjer upisanih u obrazovni sustav ima pozitivan utjecaj na ekonomski rast razvijenih zemalja.

Kvaliteta obrazovanja također je jedna od varijabli čiji se utjecaj putem uspješnosti na testovima promatrao u odnosu na ekonomski rast. Prema Hanushek i Kimko (2000), Barro (2000), Hanushek i Wößmann (2007), Altinok (2007), Appleton, Atherton, i Bleaney (2013), prosječni rezultati na međunarodnim testovima znanja i kompetencija su pokazali kako studenti mogu biti dobri indikatori procjene ljudskog kapitala te kako imaju snažan utjecaj na ekonomski rast.

[1] Mankiw, Romer i Weil (1992) se odnosi na procjenu konvergencije na uvjetno stabilno stanje, kao što je predviđeno neoklasičnim tipom modela

Benhabib i Spiegel (1994) promatraju utjecaj godina školovanja na ekonomski rast i predlažu broj godina školovanja na tri obrazovne razine kao jedan od indikatora.

Temple (1999) pronalazi pozitivan utjecaj u promjeni prosječnog broja godina školovanja prilikom korištenja drugačije strategije procjenjivanja. Barro (1996) utvrđuje kako jedna dodatna godina školovanja kod muškaraca rezultira porastom BDP-a per capita za 1.2 postotna poena. Caselli, Esquivel i Lefort (1996) također promatraju promjenu u prosječnom broju godina školovanja te zaključuju kako je kod ženskog spola ta veza pozitivno povezana s rastom. Krueger i Lindahl (2001) upozoravaju na jaku korelaciju između muškog i ženskog školovanja te koriste agregirani prosječni broj godina školovanja pronalazeći pozitivne veze za obje razine.

De la Fuente i Doménech (2006) kao i Cohen i Soto (2007) promatraju varijablu fizičkog kapitala pronalazeći robusnu pozitivnu vezu u promjenama prosječnog broja godina školovanja na rast, uz konstantni fizički kapital. U istraživanju Glaeser et al. (2004) zaključuje se kako je prosječan broj godina školovanja bolji pokazatelj rasta na dugi rok nego političke institucije.

Pregled radova koji uključuju poglavito zemlje srednje i istočne Europe započinje se radovima Heynemana (2006) i Berrymana (2000) u kojima autori smatraju kako su obrazovni sustavi u komunističkim režimima omogućili približno sveopću pismenost ruralni sredina te jednakost spolova kod pristupa obrazovanju. Sedlak (1991) ističe kako su studenti tih zemalja ostvarivali jako dobre rezultate na međunarodnim natjecanjima. Vukoja (2006) prati faktore ekonomskog rasta u 8 zemlaja srednje i istočne Europe za razdoblje od 1990. do 2003. godine te zaključuje kako postotno povećanje udjela bruto upisanih u srednje škole povećava stopu rasta za 0.2%.

Sambt, Redek, Majcen i Čok (2010) analiziraju utjecaje ulaganja u visoko obrazovanje Slovenije te zaključuju kako se kroz tri različita scenarija ulaganja može ostvariti dugoročni rast BDP-a. Nadalje Keller (2006) u svom radu procjenjuje kako model koji uključuje javne izdatke po studentu te stopu upisa objašnjava rast od 69% BDP-a per capita, uz vrlo veliku značajnost sekundarnog obrazovanja dok za visoko obrazovanje nije pronašla utjecaj.

Nakon iscrpnog pregleda literature koja se bavi raznim aspektima obrazovanja važno je uočiti kako nedostaje literature koja istražuje utjecaj visokog obrazovanja i ulaganja u visoko obrazovanje na gospodarski rast općenito u svijetu, a posebice za zemlje srednje i istočne

Europe. Stoga će se ovim radom pokušati istražiti važnosti visokog obrazovanja i ulaganja u visoko obrazovanje u navedenim zemljama.

1.2 Predmet istraživanja

Nakon iznošenja osnovne problematike kroz prethodni ulomak u ovom ćemo definirati predmeta istraživanja. Predmet ovog istraživanja je ispitivanje utjecaja ulaganja u visoko obrazovanje na ekonomski rast u zemljama srednje i istočne Europe[2] u razdoblju nakon pada komunističkog režima.

Kroz rad će se prije svega pružiti teorijska podloga važna za razumijevanje obrazovnog sustava te svih njegovih implikacija na ekonomski sustav neke države. U analizi problematike rada koristit će se analiza panel podatka za izgradnju ekonometrijskog modela na skupu zemalja iz srednje i istočne Europe te kroz određeno vrijeme.

Prednosti panel analize su u tome što se istodobno analizira i vremenska i prostorna komponenta neke pojave. Naime panel podaci sadrže veći broj podataka nego pripadajući prostorni podaci ili pripadajući vremenski nizovi. Nadalje zavisna varijabla kod panel analize se mijenja po jedinicama promatranja po vremenu pa su procjene dobivene panel analizom preciznije. Panel podaci umanjuju pristranost parametara koja se pojavljuje zbog nedostatka podataka te omogućuju definiranje i testiranje kompliciranijih ekonometrijskih modela. Određivanja intenziteta i smjera veze među varijablama je ključna stavka za interpretaciju rezultata unutar rada.

1.3 Hipoteze

Na temelju definiranog problema i predmeta istraživanja definiraju se istraživačke hipoteze:

Radne hipoteze:

H_1: Broj visokoobrazovanih utječe na ekonomski rast u zemljama srednje i istočne Europe

[2] Bugarska, Češka Republika, Estonija, Hrvatska, Latvija, Litva, Mađarska, Poljska, Rumunjska, Slovačka, Slovenija

Ova hipoteza je krucijalna za problematiku cijelog rada te se na njoj temelji cijeli predmet rada. Pokušat će se odgovoriti na pitanje kako visoko obrazovanje općenito utječe na ekonomski rast. Teorijske pretpostavke potvrđuju kako bi visoko obrazovanje trebalo imati značajan utjecaj na ekonomski rast međutim empirijskih dokaza je jako malo što je vidljivo i u zaključku rada Holmes (2013)

H_2: Ulaganje u visoko obrazovanje ima utjecaj na ekonomski rast

Postoje teorijske pretpostavke prema kojima ulaganje u visoko obrazovanje utječe pozitivno na ekonomski rast (Holmes, 2013; Keller, 2006)

Međutim, jedino su Sambt, Redek, Majcen i Čok (2010) empirijski potvrdili utjecaj ulaganja u visoko obrazovanje na ekonomski rast.

Autori neznačajnost veze između ulaganja u visoko obrazovanje i ekonomskog rasta pripisuju vremenskom odmaku koji je potreban da se rezultati ulaganja u visoko obrazovanje odraze na ekonomski rast.

Isto tako postoji mogućnost da je utjecaj varijable ulaganje indirektan, tj. da ulaganje u visoko obrazovanje utječe na broj visoko obrazovanih što se posljedično odrazi na rast BDP-a. Dakle, ovom hipotezom se nastoje ispitati smjer utjecaja ulaganja u visoko obrazovanje, odnosno je li utjecaj na rast BDP-a direktan ili indirektan te ukoliko je indirektan na koji način utječe na BDP.

H_3: Ulaganje u visoko obrazovanje ima pozitivan utjecaj na broj visokoobrazovanih populacije

Hipotezom će se pokušati dokazati teorijske pretpostavke rada Keller (2006) prema kojima ulaganje u visoko obrazovanje ima pozitivan utjecaj na broj visokoobrazovanih putem javnih izdataka po studentu u tercijarnom stupnju obrazovanja te samim tim ulaganje države u visoko obrazovanje čini ga dostupnijim.

1.4 Ciljevi istraživanja

Na temelju obrađene problematike istraživanja definiranog predmeta rada te postavljenih hipoteza slijedi razmatranje ciljeva istraživanja.

Ciljevi ovog rada su slijedeći:

1. Utvrditi postoje li i, ako postoje, kakvi su utjecaji visokog obrazovanja i ulaganja u obrazovanje na ekonomski rast zemalja srednje i istočne Europe.
2. Istražiti utječe li ulaganje u visoko obrazovanje na broj visokoobrazovanih.
3. Odabrati najbolji panel procjenitelj za procjenu panel podataka i postavljenih ekonomskih relacija.
4. Definirati karakteristike obrazovnih sustava zemalja srednje i istočne Europe na temelju provedenog istraživanja.

1.5 Metode istraživanja

Unutar ovog rada koristit će se različite metode unutar teorijskog te praktičnog dijela. Kroz teorijski dio koristit će se opće znanstvene metode koje se koriste u istraživačkim radovima kao što su: metoda indukcije i dedukcije, metoda analize i sinteze, metode dokazivanja, metoda generaliziranja te komparativna metoda[3].

- Induktivna metoda je sustavna primjena induktivnog načina zaključivanja kojim se na temelju analize pojedinačnih činjenica dolazi do zaključka o općem sudu, od zapažanja konkretnih pojedinačnih slučajeva dolazi do općih zaključaka
- Deduktivna metoda je sustavna primjena deduktivnog načina zaključivanja u kojem se iz općih sudova izvode posebni i pojedinačni zaključci te ona uvijek pretpostavlja poznavanje općih znanja na temelju kojih se spoznaje ono posebno ili pojedinačno
- Metoda sinteze je postupak znanstvenog istraživanja i objašnjavanja stvarnosti putem sinteze jednostavnih sudova u složenije

[3] Definicije metoda su preuzete sa http://www.unizd.hr/portals/4/nastavni_mat/1_godina/metodologija/METODE_ZNANSTVENIH_ISTRAZIVANJA.pdf

- Metoda generalizacije je misaoni postupak uopćavanja kojim se od jednog posebnog pojma dolazi do općenitijeg koji je po stupnju viši od ostalih pojedinačnih
- Metoda dokazivanja je jedna od najvažnijih znanstvenih metoda u koju su inkorporirane skoro sve metode i svi posebni metodički postupci, svrha joj je utvrditi točnost neke spoznaje

S druge strane u empirijskom dijelu rada koristit će se statističke i matematičke metode čiji je cilj prihvaćanje ili odbacivanje postavljenih istraživačkih hipoteza dok će se za izračune koristiti softverski alati kao što su MS Excel, Stata i drugi.

1.6 Doprinos istraživanja

Doprinos istraživanja radovima koji već postoje na području obrađivane problematike je značajan. Doprinos istraživanja vrednuje se na temelju novih i inovativnih metoda i tehnika koje je rad prikazao, u kontekstu ovog rada. Istodobno smo promatrali utjecaj ulaganja u visoko obrazovanje na broj visokoobrazovanih i na gospodarski rast te utjecaj visokog obrazovanja na ekonomski rast. U istraživanjima koja su do sada provedena za analizu utjecaja koristile su se metode jednostavne, složene regresije te koeficijenti korelacije dok će se u ovom radu koristiti panel analiza. S druge strane zemlje koje su obuhvaćene ovim istraživanjem, odnosno zemlje srednje i istočne Europe su posebno zanimljive u kontekstu obrazovanja zbog već prethodno navedene situacije za vrijeme režimskog upravljanja te nedostatka istraživanja u zemljama tog područja. Pretežno se radi o tranzicijskim zemljama u kojima su trajale intenzivne reforme obrazovanje koje su aktualne i dan danas. Dodatno, doprinos se ogleda u korištenju više različitih pokazatelja ulaganja u visoko obrazovanje te broja i udjela visokoobrazovanih

1.7 Struktura rada

Struktura rada određena je teorijskim i empirijskim dijelom te će biti strukturiran na način da zajedno sa uvodom i zaključkom sadrži 6 poglavlja. Uvodni dio rada predstavlja iznošenje problema istraživanja, definiranje predmeta istraživanja, postavljanje hipoteza koje će se

istraživati, zatim se postavljaju ciljevi istraživanja, iznose metode te doprinos koji će ovaj rad imati na već postojeću literaturu.

Drugo poglavlje rada posvećeno je obrazovnim sustavima zemalja srednje i istočne Europe u kojem će se utvrditi elementarne teorijske odrednice te iznijeti postojeća znanja o navedenoj problematici. Također u ovom dijelu se opisuju i obrazovni sustavi navedenih zemalja kroz njihovo tranzicijsko vrijeme.

Treće poglavlje je također pretežno zastupljeno teorijom i unutar njega obradit ćemo odnose između ulaganja u visoko obrazovanje te njegovog utjecaja na ekonomski rast na primjeru zemalja srednje i istočne Europe. Također ćemo definirati i varijable koje će nam predstavljati indikatore ekonomskog rasta.

Unutar četvrtog poglavlja izabirat će se varijable, formirat će se ekonometrijski model te će se vršiti izračun uz grafičke prikaze utjecaja promatranih varijabli na primjeru zemalja srednje i istočne Europe.

Peto poglavlje jedno je od najvažniji u cjelokupnom radu, unutar ovog poglavlja iznijet će se rezultati analize utjecaja visokog obrazovanja i ulaganja u visoko obrazovanje na ekonomski rast u zemljama srednje i istočne Europe. Ovo poglavlje je najvažnije za doprinos rada jer se u ovom poglavlju iznose nove spoznaje.

Kraj rada obilježava zaključak o tome kakva je veza između ulaganja u visoko obrazovanje i ekonomskog rasta, odnosno preko pokazatelja ekonomskog rasta, BDP-a.

2. OBRAZOVNI SUSTAVI ZEMALJA SREDNJE I ISTOČNE EUROPE

2.1 Teorijske odrednice obrazovnih sustava zemalja srednje i istočne Europe

Prema Lowtheru (2004) jedan od temelja razvoja konkurentnosti ljudskih resursa jest kvaliteta formalnog obrazovnog sustava. Hall (2002) te Bassani i Scarpetta (2001) dolaze do zaključka kako je u razvijenim zemljama povezanost povećanog stupnja obrazovanja i gospodarskog rasta velika. Dodatna godina obrazovanja stanovništva pojedine zemlje omogućuje povećanje proizvodnje po stanovniku za 4-7% zaključuju Bassani i Scarpetta

(2001). Prema Hanushek i Kimko (2000) za razvijene zemlje, i za one u razvoju, u određivanju ekonomskog rasta kvaliteta obrazovanja čak je i važnija od kvantitete obrazovanja. U fokusu ovog istraživanja su zemlje srednje i istočne Europe gdje je situacija bila znatno kompleksnija te ih je iz tog razloga jako teško generalno definirati. Proces transformacije u tim zemljama nije zaobišao niti jedan aspekt ekonomskog, društvenog i političkog života pa stoga ni obrazovanje nije iznimka. Politički, društveno-ekonomski i demografski poremećaji 1990.-ih godina ostavili su značajan utjecaj na obrazovne sustave. Kao zajedničko obilježje obrazovnih sustava srednje i istočne Europe u doba socijalizma može se uočiti kako je bilo uvriježeno vjerovanje u gomilanje znanja kao glavnog pokretača društvenog napretka, a ne korištenje znanja za rješavanje problema. U nastavku rada pokušat će se iznijeti određeni zaključci o trenutnom stanju obrazovnih sustava u zemljama uključenima u istraživanje.

U ovom istraživanju obuhvaćeno je 11 zemalja srednje i istočne Europe te su sve redom današnje članice Europske unije. Za navođenje teorijskih odrednica obrazovnih sustava tih zemalja koristit će se izvješće mreže Eurydice[4]. Navedeno izvješće koristi se trima glavnim izvorima: podacima mreže Eurydice, podacima Europskog statističkog sustava kojim koordinira Eurostat te podacima međunarodnog ispitivanja PISA 2009. Promatrajući obrazovne sustave u zemljama obuhvaćenima u istraživanju možemo uočiti trend dugotrajnijeg sudjelovanja u obrazovanju s ciljem stjecanje ključnih kompetencija. Nadalje prisutna je visoka autonomija škola i visokih učilišta u promatranim zemljama. To općenito podrazumijeva veću razinu autonomije u upravljanju operativnim troškovima nego u upravljanju kapitalnim troškovima. Odluke vezane uz upravljanje nastavnim osobljem također se obično donose na razini ustanove. Povećana autonomija ustanova vidljiva je i na visokoškolskoj razini u području upravljanja akademskim osobljem. Međutim, u velikoj većini zemalja središnje su vlasti i dalje odgovorne za određivanje kategorija osoblja i njihovih kvalifikacija te osnovne plaće. Posljednjih se godina sve veća važnost pridaje vrednovanju obrazovne ustanove te nastavnika s ciljem praćenja uspjeha obrazovnog sustava.

U Europi možemo izdvojiti tri različita organizacijska modela za obvezno obrazovanje. Oni se mogu definirati kao obrazovanje jedinstvene strukture (kombinirano primarno i niže sekundarno obrazovanje), zatim primarno obrazovanje kojeg slijedi integrirano sekundarno

[4] Eurydice mreža je obrazovno informacijska mreža u Europi koja pruža pouzdane i ažurne informacije s područja obrazovanja.
Raspoloživo na: http://eacea.ec.europa.eu/education/eurydice/index_en.php [18.12.2015]

obrazovanje koje čini „zajedničku jezgru“ obrazovanja te primarno obrazovanje nakon kojeg slijedi diferencirano sekundarno obrazovanje koje se ostvaruje zasebnim obrazovnim putovima. U Bugarskoj, Hrvatskoj, Estoniji, Latviji, Slovačkoj i Sloveniji opće obrazovanje se stječe u školama jedinstvene strukture koje ne zahtijevaju nikakvu vrstu prelaska s primarne na nižu sekundarnu razinu. U ovim zemljama prestanak obrazovanja jedinstvene strukture predstavlja završetak obveznog obrazovanja, osim u slučajevima Bugarske i Slovačke gdje obvezno obrazovanje završava jednu godinu poslije. U Češkoj, Mađarskoj i Slovačkoj obvezno je obrazovanje organizirano u jedinstvenoj obrazovnoj strukturi do dobi od 14 ili 15 godina, ali od dobi od 10 ili 11 godina učenici u ovim zemljama mogu u određenim fazama školovanja upisati odvojene škole koje nude programe nižeg i višeg sekundarnog obrazovanja.

U gotovo svim zemljama velika većina učenika pohađa javne škole dok u Latviji, Litvi, Rumunjskoj i Hrvatskoj taj postotak iznosi više od 98%. Između 2000. i 2009. godine u zemljama srednje i istočne Europe postotak učenika u privatnim obrazovnim ustanovama otprilike se dvostruko povećao, pri čemu se mora uzeti u obzir veoma niska razina početnih udjela.

Financiranje obrazovanja u promatranim zemljama velikom većinom se vrši izdvajanjem sredstava iz BDP-a. Kako bi se pružio što bolji uvid u financiranje svakog stupnja obrazovanja važno ih je odrediti prema međunarodnoj standardnoj klasifikaciji za obrazovanje (eng. ISCED) [5], odnosno NSKO ili Nacionalna standardna klasifikacija obrazovanja. ISCED 0 označava predprimarno obrazovanje, ISCED 1 primarno obrazovanje, ISCED 2 niže sekundarno obrazovanje, ISCED 3 više sekundarno obrazovanje, ISCED 4 postsekundarno netercijano obrazovanje, ISCED 5 prva faza tercijarnog obrazovanja te ISCED 6 druga faza tercijarnog obrazovanja.

Prema dostupnim podacima za 2008. godinu, u većini promatranih zemalja, osim Bugarske, Češke, Hrvatske, Litve i Slovačke, udio ukupnih izdataka za obrazovanje iznosio je više od 5% BDP-a.

[5] ISCED 0 – predškolsko obrazovanje, ISCED 1 – niže osnovno obrazovanje (prve četiri godine osnovnog obrazovanja), ISCED 2 – više osnovno obrazovanje (završene četiri godine osnovnog obrazovanja), ISCED 3 – srednje obrazovanje, ISCED 4 – obrazovanje nakon srednjeg koje nije tercijarno, ISCED 5 – prva faza tercijarnog obrazovanja (ne vodi do znanstvenog stupnja), ISCED 6 – druga faza tercijarnog obrazovanja (vodi do znanstvenog stupnja)

2.2 Stanje u obrazovnim sustavima za vrijeme vladavine režima

Komunističke revolucije u 20. stoljeću imale su za cilj stvaranje novog društva koje bi se razlikovalo od dotadašnjeg kapitalističkog društva. Takve promjene zahtijevale su i različite profile pojedinaca i društva kao grupe. Obrazovanje je označeno kao najvažnija strateška komponenta u ostvarivanju planova revolucije. Naime, obrazovanje je korišteno za formiranje gorljivih revolucionara spremnih na pobunu protiv starog društva te uspostavu novog poretka. Također obrazovanje u komunističkim državama uključivalo je i usađivanje određene doktrine na području politike i filozofije. Komunistički režimi istočne Europe znatno su proširili obrazovne sustave usvojene od Sovjetskog saveza, vodeći brigu o vlastitim lokalnim uvjetima, te su takvi sustavi postali temelj obrazovanja.

Marksističko – Lenjinistička filozofija bila je temelj komunističkog sustava obrazovanja. Filozofija je naglašavala ulogu obrazovnih ustanova kao instrumenata u indoktrinaciji polaznika. Iz tog su razloga komunistička društva pridavala veliku pažnju obrazovanju. Obrazovne ustanove trebale su biti stvaraoci „novog čovjeka“, marljivog radnika sa jasnim uvidom u dinamiku društvenih promjena te razumijevanjem i vještinom u modernoj tehnologiji. Prema komunističkoj filozofiji, dobro i moderno obrazovanje je ono koje se pruža na veleučilištima. Jezgra takvog obrazovanja je nauka o proizvodnji, pružanje treninga te radnog iskustva za polaznike koju su sekundarnom i visokom obrazovanju.

Ciljevi tadašnjeg obrazovnog sustava razlikovali su se u mnogočemu od današnjih. Tri krucijalne smjernice bile su smanjiti broj nepismenih osoba, obučiti populaciju za potrebe obavljanja rada političkih organizacija, poljoprivredne i industrijske proizvodnje te gospodarskih reformi i kao posljednja smjernica, promijeniti ponašanje i stavove ljudi.

Studenti su dobili intenzivnu obuku za obavljanje određenih programa kao što su agrarni, industrijski te poljoprivredni. Obrazovne ustanove bile su organizirane u velike visoko centralizirane državne sustave te ih je karakterizirala sekularnost. Osnovna škola je bila organizirana kroz najmanje sedam ili osam razreda, nastavni plan, kao i literatura, bio je čvrsto propisan od strane režima. Većina literature, osobito iz područja znanosti i tehnologije, bila je prijevod sovjetskih knjiga. Sustav obrazovanja u zemljama istočne Europe također je karakterizirala uska povezanost obrazovnih ustanova s planiranim potrebama ekonomskog razvoja, širenje obrazovnih mogućnosti osobito za ženski spol te ruralna područja koja su do tada bila zapostavljena. Dotadašnji formalni klasični kurikulum zamijenio je kurikulum s

naglaskom na matematiku i prirodne znanosti. Zadovoljavanje individualne potražnje za obrazovanjem na sekundarnoj i tercijarnoj razini imalo je jako nizak prioritet.

Ovakva politika dovela je do porasta razine obrazovanja populacije u tolikoj mjeri da je u određenim zemljama postojao višak visokoobrazovanih osoba nasuprot manjku radnika s tehničkim kvalifikacijama. Unatoč znatnom napretku i nastavku golemog ulaganja u obrazovanje pojavila su se određena ograničenja i problemi. Neki od uočenih problema i ograničenja bili su nedostatak predanosti visokim socijalnim i moralnim svrhama, rastući troškovi obrazovanja, nefleksibilnost školskog sustava u odnosu na društvene i ekonomske promjene te problemi raspodjele rada.

Posljedice takvih režima dovele su do relativno slabog razvoja obrazovanja u komunističkim zemljama između 1960. i 1981. Razlog leži u prethodno navedenim ograničenjima i problemima komunističkog režima kao što su nefleksibilnosti sustava, maloljetničko prijestupništvo te rastućim troškovima

2.3 Obrazovni sustavi nakon raspada režima

Značajno gospodarsko i kulturno nazadovanje komunističkih zemalja u odnosu na zemlje zapada dovelo je do velikog nezadovoljstva među stanovništvom, te su se diljem Europe pokrenule revolucije protiv režima. Prema Pastuoviću (2012) u visokoideologiziranim društvima, kakvo je bilo komunističko, gospodarska i politička modernizacija usporena je ili onemogućena dominantnim vrijednosnim obrascem. U komunističkim zemljama program obrazovanja prožet je vrijednostima proklamiranog poretka kako bi škola proizvela svjesne građane otporne na „pogubne buržoaske utjecaje“. Time škola doprinosi stabilizaciji političkog poretka koji je pak učinio nekonkurentnim plansko komunističko gospodarstvo SSSR-a zbog čega se njegov društveni sustav konačno urušio. Nakon raspada režima, novoformirane zemlje stekle su okvirnu političku podlogu za početak gospodarske tranzicije. Sukladno tomu okreću se tržišnoj privredi te demokratskom društvu. Pastuović (2012) dalje navodi kako se u pravilu drži da je doprinos obrazovanja gospodarstvu veći u tržišnoj nego u planskoj privredi te kako je doprinos obrazovanja političkom razvoju veći u demokratskom društvu nego u totalitarnom. Gospodarska tranzicija, i onda kada su za nju stvorene okvirne političke pretpostavke, može potrajati više godina, dok je za promjenu dominantnog

vrijednosnog obrasca stanovništva potrebno i nekoliko generacija. Kultura, definirana sustavom vrijednosti stanovništva i obrascima društvenog ponašanja kojima se vrijednosti očituju, najmasivniji je i najtromiji dio društvenog sustava pa može usporavati političku i gospodarsku modernizaciju.

Što se tiče reformi koje su pokrenute u zemljama srednje i istočne Europe nastalim nakon raspada režima, Birzea (1996) razlikuje četiri tipa reforma: korektivne reforme, modernizirajuće reforme, strukturne reforme i sistemske reforme. U zemljama koje su predmet istraživanja rada dominiraju korektivne reforme, kojima je pribjegla većina postkomunističkih zemalja Europe nakon 1990. godine. Prema Pastuoviću (2012) korektivne reforme svode se na promjene nekih vidljivih simboličkih karakteristika sustava što su se očitovale u isključivanju ideologiziranih programa iz bivšeg režima i uvođenju programa s nacionalnim i vjerskim predznakom, a bez zadiranja u strukturu sustava.

Većina zemlja iz zapadnog dijela Europe je prošla razdoblje strukturnih reformi te se one nalaze u fazi primjene te prilagođavanja već postojećih reformi. Zapadnoeuropske zemlje imaju za cilj poboljšanje obrazovanja koje će dovesti do boljih obrazovnih rezultata na međunarodnim testovima te samim tim i boljih obrazovnih ishoda dok istodobno anuliraju uzroke koji dovode do preranog napuštanja školovanja. S druge strane, tranzicijske zemlje provele su prvu fazu, odnosno korektivne reforme. U slučaju tih zemalja korektivne reforme imaju samo simboličan značaj i odnose se na izradu projekata ili tzv. „bijelih knjiga“ o sustavnim promjena obrazovanja s naglaskom na promjene u strukturi. Većina zemlja je izmijenila i prilagodila zakonski okvir obrazovanja, ali nedostaju određene stručne i materijalne pretpostavke za uspješnu reformu.

Prema Pastuoviću (1993) zbog međuovisnosti gospodarskih i strukturnih društvenih promjena te javnih politika, stupanj provedenih društvenih promjena u nekoj zemlji u velikoj mjeri određuje strukturne promjene obrazovanja.

Rado (2001) u svom radu navodi kako su u Poljskoj i Mađarskoj i u zemljama u kojima je završena privatizacija, strukturna transformacija gospodarstva, u kojima je stvorena pravna okolina tržišnog gospodarstva te u kojima rastu strana ulaganja prisutni potpuno drugačiji uvjeti za obrazovnu reformu nego Slovačkoj i Rumunjskoj koje su u tom smjeru učinile tek prve korake. Pastuović (2012) dalje navodi kako su zemlje koje su započele ograničene reforme još u vrijeme bivšeg režima kao što su Mađarska, Poljska i Slovenija nešto lakše provele svoje strukturne reforme još u postkomunističkom razdoblju. Modernizacija društva

do koje je došlo pristupanjem Europskoj uniji doprinijela je daljnjoj modernizaciji obrazovanja. U modernizacijskom procesu moguće su sektorske neravnoteže pa obrazovanje lako može, zbog zauzetosti vlasti gospodarskim i političkim prioritetima, zaostati za promjenama u drugim dijelovima društva. Kako bi se izbjegle određene pogreške važno je društvenom konsolidacijom stvoriti što bolje uvjete za osmišljavanje i provođenje reformi.

Podaci o kretanjima u regiji pokazuju da se razine obrazovnih postignuća smanjuju te sužavaju u segmentima populacije koja ulazi u tercijarnu razinu obrazovanja. Ovo dokazuje kako se smanjuju te napuštaju politike i prakse koje su za vrijeme režima promicale jednake mogućnosti pristupa visokom obrazovanju.

Cerych (1995) u svom radu iznosi dva aspekta reforme obrazovanja u zemljama srednje i istočne Europe koja se razlikuju od konteksta u kojem je većina reformi obrazovanja provedena. Prvo, širina, raspon i dubina predloženih reformi ili reformi koje su već provedene je enormno velika. Reforme u zemljama srednje i istočne Europe obuhvaćaju skoro sve razine i sektore uključenje u obrazovanje, od strukture cijelog sustava, kurikuluma, obrazovnog zakonodavstva, upravljanja i financiranja sustava. U vrijeme komunizma reforme su bile pod centraliziranom i totalnom kontrolom režima dok se danas teži demokratizaciji te većoj autonomiji sustava. S druge strane brzina procesa reformi je također specifična.

Nadalje Cerych (1995) kao i Pastuović (2012) navodi neke od faktora koji su utjecali na implementaciju reformi obrazovanja u razdoblju tranzicije. „Nasljedstvo“ komunističkog režima jedan je od glavnih uzroka teškog provođenja reformi u zemljama srednje i istočne Europe. Pod nasljedstvom se podrazumijeva čitav niz aspekata sociološke prirode kao što su radne navike u bivšem režimu, duboko ukorijenjena praksa djelovanja samo prema detaljnim uputama „odozgo“ te zastarjeli sadržaj i metode podučavanja. Ovaj faktor je jako teško izmjeriti jer ne postoje podaci ni ankete koje bi omogućile uvid u promjene ponašanja i navika glavnih aktera obrazovanja. Općenito se procjenjuje da sektor inovacija u nerazvijenijim zemljama srednje i istočne Europe zauzima svega 15-20% što znači da se, u 80-85% slučajeva povezanih sa nekim od osnovnih aspekata razvoja obrazovanja, cjelokupni sustava obrazovanja još nije previše promijenio.

U svom drugom radu Cerych (1999) navodi četiri prijelomne točke u obrazovanju. Prva točka se odnosi na depolitizaciju obrazovanja, odnosno na prekid strogih i čvrstih ideoloških kontrola i orijentacije sustava, druga točka se odnosi na prekidanje državnog monopola te dopuštanje osnivanja privatnih i religijskih obrazovnih institucija. Treća točka otvara pravo

izbora obrazovnog puta temeljenog na osobnim preferencijama te sposobnostima polaznika. I za kraj četvrta točka decentralizira upravljanje i administraciju nad obrazovnim sustavom. Ove promjene su predstavljene u pretežno svim zemljama srednje i istočne Europe te impliciraju stvarnu revoluciju sa dugoročnim posljedicama.

Cerych (1995) kao i Pastuović (2012) smatraju kako će se reforme provesti teško te kako treba relativno dugo vremensko razdoblje za provedbu. S druge strane u zemljama srednje i istočne Europe reforme su osmišljene, prihvaćene te implementirane tijekom prve dvije godine tranzicijskog razdoblja u svega nekoliko mjeseci. Stoga istraživanje utjecaja visokog obrazovanja i ulaganja u visoko obrazovanje u spomenutim zemlja postaje krucijalna tema ovoga rada.

U nastavku rada teorijski će se obraditi značaj visokog obrazovanja u zemljama srednje i istočne Europe, odnosi te utjecaj na gospodarski rast na temelju dostupne i postojeće literature.

3. ZNAČAJ VISOKOG OBRAZOVANJA U ZEMLJAMA SREDNJE I ISTOČNE EUROPE

3.1 Teorijski aspekti utjecaja obrazovanja na ekonomskog rasta

Visoko obrazovanje ima važnu ulogu za kolektivnu dobrobit cijele Europe zbog stvaranja novih znanja koji se prenose na studente. Velika institucionalna raznolikost u Europi jedna je od glavnih snaga visokog obrazovanja. Poznato je kako gotovo četiri tisuće visokoobrazovnih ustanova u Europi, koje djeluju unutar zakonskih i upravljačkih okvira vlastitih zemalja, djeluju i stvaraju raznolikost visokog obrazovanja. Van Vught (2010) zaključuje kako upravo ta raznolikost ima pozitivan utjecaj na performanse visokoobrazovnih ustanova. Čak i ako govorimo o malim specijaliziranim obrazovnim ustanova ili velikim sveučilištima, njihova uloga u sustavu visokog obrazovanja Europe je vrlo važna.

Reforme visokoobrazovnog sustava kontinuirano su prisutne u gotovo svim zemljama Europe. Havelka (2003) smatra kako stalne društveno-političke, gospodarske i tehnološke promjene traže nove pristupe i nove sadržaje u visokom obrazovanju, brže usvajanje novih znanja i vještina kako bi krajnji proizvod ovog sustava, visokoobrazovani stručnjak bio

prilagođen novim društvenim potrebama. Zbog velikih povijesnih razlika u prevladavajućim modelima visokog obrazovanja u tranzicijskim zemljama i razvijenim zemljama Europe, postoje i značajne razlike u načinu, dinamici i sadržaju reorganizacije visokog obrazovanja. Prilikom usklađivanja obrazovnog prostora tranzicijske zemlje su pod određenim pritiskom razvijenih zemalja koje imaju za cilj stvaranje jedinstvenog društveno-političkog i gospodarskog europskog sustava u kojem će postojati zajedničko tržište radnog kapitala.

Nakon raspada režima u srednjoj i istočnoj Europi visoko obrazovanje oblikovalo se na temelju postkomunističkih iskustava u visokom obrazovanju te prema principima američkog modela za visoko školstvo (odnosi se na Mađarsku i Rumunjsku) odnosno prema britanskom modelu u baltičkim državama. Analizirajući procese koji su prethodili dokumentu pod nazivom Standardi i smjernice za osiguranje kvalitete visokog obrazovanja u europskom obrazovnom prostoru (engl. *Standards and Guidelines for Quality Assurance in the European Higher Education Area*[6]), Kohoutek (2009) dolazi do zaključka kako je implementacijom navedenog dokumenta ostvaren značajan napredak u području visokog obrazovanja. U zemljama srednje i istočne Europe proces reforme visokog obrazovanja započinje usvajanjem iskustava iz predbolonjskog procesa, određenih prednosti iz provedbe standarda i smjernica za osiguranje kvalitete i visokog obrazovanja u europskom obrazovnom prostoru te od regionalne mreže za osiguranje kvalitete visokog obrazovanja u zemljama srednje i istočne Europe.

Prema Stevensu i Wealeu (2003) postoje dva osnovna razloga zbog koji se može očekivati pronalaženje veze između obrazovanja i ekonomskog rasta. Prije svega uočljivo je kako je životni standard porastao tijekom posljednjeg tisućljeća zbog obrazovanja. Za većinu promatrača čini se kako mora postojati veza između znanstvenog unaprjeđenja i načina na koji je obrazovanje omogućilo razvoj znanja. Drugi, specifičniji razlog, je širok raspon ekonometrijskih istraživanja koja pokazuju kako prihodi pojedinaca ovise o stupnju obrazovanja. Ukoliko obrazovani ljudi zarađuju više, ista situacija bi trebala biti prisutna i na razini zemalja. Aghion et al. (2009) zaključuju kako postoji mnogo korelacijskih dokaza i empirijskih istraživanja koja dokazuju da su gospodarski rast i obrazovanje povezani, ali su rezultati različiti od zemlje do zemlje kao i jačina utjecaja. Ukoliko bi uspoređivali situaciju na primjeru Europe i SAD-a u posljednjih nekoliko godina, kada je Europa rasla sporije, možemo zaključiti kako je Europa rasla sporije zbog relativno niskog udjela investicija za

[6] http://www.enqa.eu/wp-content/uploads/2013/06/ESG_3edition-2.pdf

obrazovanje u bruto domaćem proizvodu. Ako bi isti utjecaj promatrali kroz razdoblje od trideset godina nakon Drugog svjetskog rata, Europa je rasla znatno brže od SAD-a iako je većina ulaganja obuhvaćala osnovno i srednjoškolsko obrazovanje. Jasno je kako odnos obrazovanje – ekonomski rast nije jednostavan te se ne može izračunati prosječan broj godina trajanja obrazovanja i na temelju toga pouzdano predvidjeti rast. Ukoliko se želi utvrditi koliko obrazovanje pridonosi ekonomskom rastu moramo usporediti države koje pripadaju sličnoj geografskoj regiji, koje imaju sličnu političku situaciju u povijesti te sličan razvojni put.

U ovom istraživanju obuhvaćene su zemlje srednje i istočne Europe za koje vrijede sve navedene karakteristike. Utjecaj obrazovanja na rast kao tema bila je i još uvijek je predmetom mnogih istraživanja i radova. Rezultati istraživanja su vrlo kontradiktorni, tako su neki otkrili značajne pozitivne odnose, dok su drugi pronašli negativne odnosno nikakve utjecaje. U nastavku rada će se navesti dosadašnja empirijska istraživanja značaja obrazovanja.

3.2 Pregled dosadašnjih empirijskih istraživanja značaja obrazovanja

Postoji veliki broj istraživanja koji se bavi utjecajem obrazovanja na ekonomski rast te je većina tih istraživanja provedena za razvijene zemlje dok je za zemlje srednje i istočne Europe broj istraživanja daleko manji. Većina istraživanja ispituje utjecaj cijelog obrazovnog sustava na gospodarski rast, dok manji broj istraživanja istražuje utjecaj visokog obrazovanja. Radovi se prema problematici mogu razvrstati u više grupa.

Prva grupa empirijskih radova su oni koji se bave pronalaženjem povezanosti između obrazovanja i rasta. Grupa započinje radom Barro i Leeja (1993) u kojem autori opisuju skup podataka o stupnju obrazovanja za 129 zemalja, svakih 5 godina od 1960. – 1985. godine. Naime, autori su pojam ljudskog kapitala izrazili preko broja godina završenog obrazovanja za osobe od 25 i više godina. Za navedenu populaciju definirali su prosječnu postignutost obrazovanja na sedam razina: bez obrazovanja, nezavršeno primarno obrazovanje, završeno primarno obrazovanje, prvi ciklus sekundarnog obrazovanje, drugi ciklus sekundarnog obrazovanja, nezavršeno tercijarno obrazovanje te završeno tercijarno obrazovanje. Autori su koristili pismenost populacije u navedenim zemljama kao proxy za razinu bez obrazovanja. U

nastavku istraživanja navode kako ukupni broj godina obrazovnih postignuća za oba spola ima pozitivan utjecaj na stopu rasta BDP-a per capita, te kako obrazovna postignuća muške populacije imaju veću važnost. Barro i Sala-i-Martin (2004) navode kako zemlje s većim BDP-om per capita obično imaju veću stopu ljudskog kapitala u formi obrazovnih postignuća nego u formi fizičkog kapitala. Ovo opažanje sugerira kako bi se omjer populacije u fizičkom kapitalu povećao tijekom porasta realnog BDP-a per capita. Chatterji (1998) u svom radu promatra utjecaje sekundarnog i tercijarnog obrazovanja na ekonomski rast u 81 zemlji. Navodi kako je tercijarno obrazovanje istisnulo sekundarno obrazovanje kao glavnog pokretača ekonomskog rasta. Nadalje, pri izostavljanju tercijarnog obrazovanja iz analize autor je dobio vrlo slab utjecaj dok je izostavljanje sekundarnog obrazovanja rezultiralo suprotnim učinkom. Levine i Renelt (1992) sustavno procjenjuju robusnost parcijalnih korelacija između stopa rasta BDP-a per capita i velikog broja ekonomskih indikatora te dolaze do saznanja kako stopa omjera upisanih u primarno i sekundarno obrazovanje nije robusno korelirana sa stopom rasta. Dok s druge strane, Baldacci et al. (2008) navode kako povećani omjer upisanih u obrazovni sustav ima pozitivan utjecaj na ekonomski rast razvijenih zemalja. Barro i Sala-i-Martin (1995, u Vukoja 2006) koriste cross-country analizu na uzorku 90 zemalja u razdoblju 1965.-1985., te pokazuju da je prosječna stopa rasta BDP-a per capita pozitivno korelirana s razinom stečenog obrazovanja (kao referentnu točku autori koriste srednjoškolsko obrazovanje), s udjelom investicija (privatnim i javnim) u BDP-u, s uvjetima trgovine te s očekivanom duljinom životnog vijeka, dok je ista negativno korelirana s udjelom državne potrošnje u BDP-u. Iako se iz njihove analize može izvući zaključak da strukturne varijable koje nisu naglašene kao odrednice dugoročnog rasta u Solow-Swan modelu, imaju jak utjecaj na mogućnost rasta pojedine ekonomije, treba imati na umu i povratni efekt rasta na navedene ekonomske varijable. Tako je vrlo vjerojatno da će se, kako pojedina zemlja postaje razvijenija, veći dio BDP-a investirati i u fizički kapital i u obrazovanje, što ujedno predstavlja problem obrnute kauzalnosti.

Promatrajući kvalitetu obrazovanja, rezultate na međunarodnim testovima znanja i kompetencija te njihov utjecaj na ekonomski rast Hanushek i Kimko (2000) dolaze do zaključka koji proizlazi iz različitih analitičkih specifikacija i govori kako kvaliteta radne snage ima dosljednu, stabilnu i snažnu vezu sa ekonomskim rastom. Nadalje promatrajući dohotke stranaca u SAD-u navode kako se međunarodni testovi znanja i kompetencija odnose na razlike u produktivnosti koje su povezane sa obrazovnim razlikama. Direktna povezanost sa produktivnošću sugerira uzročni utjecaj na ekonomske performanse. Procijenjeni utjecaj

kvalitete na ekonomski rast kazuje kako jedna standardna devijacija u postignućima iz matematike i znanosti rezultira s prosječnim porastom godišnjeg rasta za više od jednog postotnog poena. Hanushek i Wößmann (2007) smatraju kako kvaliteta obrazovanja, mjerena količinom znanja, ima snažan utjecaj na dohodak pojedinca, distribuciju prihoda te na ekonomski rast. Altinok (2007) u svom radu izrađuje kvalitativni pokazatelj ljudskog kapitala za 105 zemalja u razdoblju između 1964. i 2005. godine. Appleton, Atherton i Bleaney (2013) u svom radu prvo koriste panel analizu za obradu podataka samo kako bi testirali rezultate na ranijim datumima te nakon toga koriste prostorne podatke. U oba slučaja zaključuju kako je utjecaj kvalitete obrazovanja na gospodarski rast statistički značajan.

Grupa radova koji se bave utjecajem godina školovanja na ekonomski rast započinje radom Benhabib i Spiegel (1994) koji predlažu prosječan broj godina školovanja na tri obrazovne razine kao jedan od indikatora prema provedenoj studiji na temelju 78 države u vremenskom razdoblju od 1965.-1985. godine. Autori pokazuju znatno manji doprinos ljudskog kapitala u objašnjenju stope rasta per capita dohotka. Njihovi rezultati upućuju na zaključak kako ljudski kapital djeluje na rast preko tehnološkog razvoja. Temple (1999), promatrajući više različitih država širom svijeta (Nigerija, Kina, Indija, Pakistan, Iran, Tajland, Brazil, Argentina, Japan, SAD, itd.) zaključuje kako postoji pozitivan utjecaj u promjeni prosječnog broja godina školovanja na ekonomski rast prilikom korištenja drugačije strategije procjenjivanja. S druge strane, Barro (1996) utvrđuje kako početna razina prosječnog broja godina školovanja među muškim osobama od 25 i više godina je pozitivna, odnosno: jedna dodatna godina školovanja rezultira porast BDP per capita za 1.2 postotna poena. Istovremeno, zaključuje kako prosječan broj godina školovanja među ženama nema pozitivnog utjecaja.

Ipak Caselli, Esquivel i Lefort (1996) u svom radu osporavaju postojeće stanje, tvrdeći kako se empirijska literatura o cross-country rastu oslanja na nedosljedne postupke procjene. Prema tome, brzinu konvergencije i ostale koeficijente rasta koji su dobiveni u dosadašnjim radovima smatraju nepouzdanima. Koristeći panel analizu metodom generalizirane metode momenata zaključuju kako broj godina obrazovanja kod žena ima pozitivan učinke na rast. Novi rezultat do kojeg su autori došli je robusni pozitivni doprinos rastu koji se ostvaruje državnom potrošnjom na vojni i obrazovni sektor. Krueger i Lindahl (2001) tvrde kako je razlog ovakvih nedosljednosti jednostavno jaka korelacija između muškog i ženskog školovanja, što upozorava kako treba biti oprezan s rezultatima iz zasebnih mjera. Stoga, autori koriste agregirani prosječni broj godina školovanja te pronalaze pozitivne veze za obje

razine, interpretirajući kako obrazovanje pozitivno djeluje kao proizvodni faktor te putem inovacija i difuzija.

Nadalje neki autori uključuju u promatranje varijablu fizičkog kapitala. De la Fuente i Doménech (2006) kao i Cohen i Soto (2007) predstavljaju nove i kako sami tvrde bolje podatke, pronalazeći robusnu pozitivnu vezu u promjenama prosječnog broja godina školovanja na rast, uz konstantni fizički kapital. U međuvremenu, Glaeser, La Porta, Lopez-de-Silanes i Shleifer (2004) zaključuje kako je prosječan broj godina školovanja bolji pokazatelj rasta na dugi rok nego političke institucije, što je u skladu s teorijom koju zagovaraju Bhattacharyya i Jha (2013).

Prethodno navedeni radovi imaju zajednički problem, jako je teško procijeniti robusnost rezultata. Različiti modeli uključuju različite varijable što omogućuje stvaranje takve pozitivne veze koja zapravo više reflektira specifične karakteristike modela nego što prikazuje stvarne veze između prosječnog broja godina školovanja i rasta.

Henderson, Papageorgiou i Parmeter (2012) koriste pet različitih baza podataka sa prosječnim brojem godina školovanja te provode stroge testove ispitujući utjecaje obrazovanja na ekonomski rast. Autori pronalaze jako malo dokaza o utjecaju broja godina školovanja na ekonomski rast. Castelló-Climent i Hidalgo-Cabrillana (2012) nadalje istražuju te zaključuju kako veza između količine obrazovanja i rasta nije jasna kao što se misli. Oni pronalaze pozitivni efekt u zemljama u razvoju, dok ne pronalaze nikakav efekt u razvijenim zemljama. Međutim rezultati se temelje isključivo na osnovnim statističkim analizama te se trebaju interpretirati s oprezom.

Svega nekolicina radova provedena je za zemlje srednje i istočne Europe. Prema Heynemanu (2006) i Berrymanu (2000) obrazovni sustav koji se razvio za vrijeme komunističkog pokreta u državama srednje i istočne Europe učinkovito je dosegao blizinu sveopće pismenosti odraslih u urbanim i ruralnim populacijama te postigao rodnu jednakost u pristupu obrazovanju. Prema Sadlaku (1991) studenti iz tih zemalja redovito su sudjelovali na međunarodnim školskim natjecanjima te su bili smješteni na ili u blizini vrha na području matematike i znanosti. Uspjeh je bio inspiriran ideologijom komunizma koja se zbog političkog legitimiteta trebala pojaviti u svrhu interesa „radne i seljačke“ klase koja je činila većinu stanovništva u tim društvima.

Na temelju podataka prikupljenih od strane OECD-a možemo ilustrirati neke od linija rasjeda koje su se počele javljati u obrazovnim kapacitetima zemalja srednje i istočne Europe. Broj godina koje je trebalo šestogodišnjem djetetu u zemljama srednje i istočne Europe za završetak cjelokupnog školovanja (ne uključujući predškolsko razdoblje), 1989. iznosilo je 11.21 godina. Do 1997. godine razina se spustila na 10.57 godina. Usporedbe radi, u zemljama zapadne Europe razina godina potrebnih za cjelokupno obrazovanje 1998. iznosila je 15.4 godina te je pokazivala uzlazni trend.

Vukoja (2006) prati faktore ekonomskog rasta u 8 zemalja srednje i istočne Europe za razdoblje od 1990. do 2003. godine. Kao zavisna varijabla korištena je prosječna godišnja stopa rasta BDP-a per capita, dok su kao nezavisne varijable korištene udio investicija u BDP-u, prosječna godišnja stopa rasta stanovništva, udio međunarodne razmjene u BDP-u, udio države u BDP-u te postotak bruto upisanih u srednje škole. Prema rezultatima regresije postotno povećanje udjela bruto upisanih u srednje škole, ceteris paribus, povećava stopu rasta za 0.2%. Iz danog pregleda vidljiv je očiti nedostatak radova koji se bave ispitivanjem utjecaja visokog obrazovanja na ekonomski rast.

3.3 Pregled empirijskih istraživanja odnosa između visokog obrazovanja i ekonomskog rasta u zemljama srednje i istočne Europe

Globalni institut McKinsey u svom izvješću (2013) navodi kako srednja i istočna Europa imaju opsežne obrazovne sustave i relativno dobro obrazovanu populaciju. Međutim, unatoč dosadašnjem uspjehu regije u stvaranju visokoobrazovane populacije, morat će uložiti dodatne napore i investicije u obrazovanje kako bi konkurirali drugim zemljama u razvoju. Izvješće navodi kako postoji puno prostora za unaprjeđenje obrazovanja te unatoč dobroj razini obrazovnih postignuća zaostaju za zemljama OECD-a. Prema PISA testovima, koji ispituju znanja i vještine petnaestogodišnjih učenika, rezultati za zemlje srednje i istočne Europe su ispod prosjeka zemalja OECD-a koji iznosi 493. Primjerice, Rumunjska ima 424, Bugarska 429, Hrvatska 476 dok jedino Poljska ima rezultat iznad prosjeka OECD-a i on iznosi 500. Također, izvješće navodi kako se samo 7 sveučilišta i visokoobrazovnih ustanova u zemljama srednje i istočne Europe nalazi unutar 500 najboljih ustanova u svijetu.

Često se kvalitetan sustav obrazovanja smatra nužnim preduvjetom za ekonomski rast što je već spomenuto. Također važnost visokog obrazovanja i ulaganja u visoko obrazovanje se često ističe međutim empirijskih radova je jako malo.

Istraživanje o važnosti ulaganja u obrazovanje provela je Katarine Keller (2006) prema kojemu autorica ispituje tri mjere ulaganja u obrazovanje na primjeru Velike Britanije: stopa upisa, javne izdatke za obrazovanje kao udio u BDP-u te, javne izdatke po studentu kao udio BDP per capita. Procjenjivala je individualne efekte primarnog, sekundarnog te tercijarnog obrazovanja te njene procjene ukazuju kako model koji uključuje javne izdatke po studentu te stopu upisa objašnjava rast od 69% BDP-a per capita, uz vrlo veliku značajnost sekundarnog obrazovanja dok za visoko obrazovanje nije pronašla utjecaj.

Kubik (2015) u svom radu testira povezanost između triju razina školovanja i ekonomskog rasta koristeći metodu generaliziranih momenata na primjeru panel podataka za 86 zemalja, među kojima su i zemlje srednje i istočne Europe, u razdoblju od 1960 – 2005 godine. Prosječan broj godina školovanja koristi kao proxy za efekt ljudskog kapitala na ekonomski rast te uzima ekonomski rast za zavisnu varijablu. Rezultati pokazuju kako postoji pozitivni utjecaj sekundarnog i tercijarnog obrazovanja na ekonomski rast. Porast udjela stanovništva s tercijarnim obrazovanjem za 1% može povećati ekonomski rast za približno 1,5%.

Pregled empirijskih radova nastavljamo na primjeru Slovenije. Sambt, Redek, Majcen i Čok (2010) promatraju utjecaje povećanja javnih ulaganja u tercijarno obrazovanje na primjeru kroz tri scenarija. Prvi scenarij povećanja javnih ulaganja u obrazovanje bio bi putem povećanja javnog duga, drugi putem smanjenja ostalih javnih izdataka, a treći kroz povećanje poreza na cijenu koju potrošač plaća. Zaključak do kojeg su došli je kako povećanje javnih izdataka za tercijarno obrazovanje od 0.3 postotna poena od BDP bi rezultiralo pozitivnim dugoročnim učincima na povećanje BDP između 0.05 postotnih poena i 0.11 postotnih poena na godišnjoj razini.

Kao što je prethodno navedeno, Holmes (2013) u svom radu pokušava empirijski iskazati utjecaje sve tri razine obrazovanja na ekonomski rast. On u radu ne nalazi vezu između visokog obrazovanja i ekonomskog rasta ali sumnja da je do takvog rezultata došlo zbog greške ili korištenja pogrešne metode. Važno je također napomenuti kako je vidljiv i nedostatak empirijskih istraživanja koja potvrđuju utjecaj visokog obrazovanja na gospodarski rast te se javlja potreba za iskazivanjem utjecaja ulaganja u visoko obrazovanje na gospodarski rast. Međutim postoji mogućnost da takav utjecaj ne bude direktan s obzirom

da je potrebno neko vrijeme da se rezultati ulaganja u visoko obrazovanje odraze na gospodarski rast. Uz to prilikom pregleda literature vidljivo je kako autori često napominju nedostatke korištenih statističkih metoda. Najčešće korištene metode su koeficijent korelacije te jednostavna i složena regresija dok samo nekolicina koristi analizu panel podataka. Stoga bi ovaj rad, u metodološkom smislu, mogao unaprijediti dosadašnja istraživanja korištenjem panel analize.

Nedostatak istraživanja utjecaja visokog obrazovanja, ulaganja u visoko obrazovanja na ekonomski rast te rezultati istraživanja Sambt, Redek, Majcen i Čok (2010) su glavni faktori koji su potaknuli na provođenje ovog istraživanja u kojem će se pokušati dobiti odgovor utječe li ulaganje u visoko obrazovanje na ekonomski rast, utječe li broj visoko obrazovanih na ekonomski rast i ima li ulaganje u visoko obrazovanje pozitivan utjecaj na broj visokoobrazovane populacije.

4. ANALIZA PANEL PODATAKA[7]

4.1 Osnovne karakteristike panel analize

Prema Škrabić Perić (2012) panel analiza, kao ekonometrijska tehnika, je postala neizostavan dio empirijskog dijela znanstvenih istraživanja, doktorskih disertacija, a i magistarskih radova. Popularnost panel analize nije začuđujuća zbog toga što istovremeno uzima u obzir vremensku i prostornu komponentu. Za upotrebu višestruke regresije nužno je odlučiti se želi li se analizirati prostorna komponenta ili vremenska komponenta neke pojave. Dakle, prije pojave panel analize nije bilo moguće istovremeno analizirati više jedinica promatranja u nekom razdoblju. Čest problem u praksi je prikupiti podatke koji imaju dovoljno dugu vremensku dimenziju za kvalitetnu analizu. Isto tako teško je prikupiti dovoljno jedinica promatranja da bi rezultati višestruke regresije bili relevantni. Prednost panel analize je u tome što podaci koji nisu bili dovoljni za analizu vremenskih nizova niti za prostornu analizu udruženi u panel podatke mogu dati kvalitetne empirijske rezultate. Panel analiza je našla primjenu u svim područjima ekonomije na mikro i makro razini.

[7] Preuzeto u potpunosti iz Aljinović, Z., Marasović, B. (2012). Matematički modeli u analizi razvoja hrvatskog financijskog tržišta. Ekonomski fakultet u Splitu, Split.

Prije pojave panel analize za analizu podataka koristila se višestruka regresija na prostornim podacima ili vremenskim nizovima. S vremenom su vremenski nizovi postali duži, a prostorni podaci su sadržavali sve više opažanja pa su rezultati analiza postali kvalitetniji. Unatoč sve kvalitetnijim i preciznijim ekonometrijskim analizama u empirijskim istraživanjima pojavila se potreba da podaci koji se analiziraju imaju istovremeno vremensku i prostornu komponentu. Podaci koji sadrže vremensku i prostornu komponentu neke varijable nazivaju se panel podaci. Da bi se oformila baza podatka potrebna za panel analizu, moraju se prikupiti podaci o jedinicama promatranja (pojedincima, poduzećima, gradovima, državama i sl.) kroz vrijeme. Za analizu panel podataka nije uvijek moguće korištenje obične višestruke regresije jer se ne može pretpostaviti nezavisnost među opažanjima jedne jedinice promatranja kroz vrijeme. S obzirom na prirodu panel podataka, za njihovu ekonometrijsku analizu razvijene su posebne metode i modeli.

Škrabić Perić (2012) dalje navodi kako su prednosti panel analize te što panel podaci omogućavaju definiranje i testiranje kompliciranijih ekonometrijskih modela. Panel podaci također umanjuju problem multikolinearnosti, naime dogodi li se da su dvije varijable iste jedinice promatranja snažno korelirane, ali ta korelacija nije izražena između jedinica drugih jedinica promatranja, ta korelacija gubi značajnost. Autorica dalje navodi kako panel podaci moraju biti homogeni, tj. jedinice promatranja moraju imati zajednička svojstva. Ukoliko taj uvjet nije ispunjen rezultati analize neće biti relevantni, odnosno često se niti jedna varijabla ne pokaže statistički značajnom. Prema kriteriju raspoloživosti podataka razlikujemo *balansirane panel podatke* tj., ako su za svaku jedinicu promatranja u svakom razdoblju, za sve varijable dostupni potrebni podaci te *nebalansirane panel podatke*, tj. ako za bilo koju jedinicu promatranja nedostaje podataka za neku varijablu u nekom razdoblju . S druge strane, prema ovisnosti o zavisnoj varijabli razlikuju se ***statički*** i ***dinamički*** modeli koji će se detaljnije razraditi u nastavku rada

4.2 Statički panel modeli

4.2.1 Združeni panel model

Združeni panel model (engl. Pooled OLS) je najjednostavniji panel model, a definira se kao:

$$y_{it} = \alpha + \beta_1 \cdot x_{it1} + \beta_2 \cdot x_{it2} + ... + \beta_K \cdot x_{itK} + \varepsilon_{it}; \qquad i = 1,...,N; t = 1,...,T; \tag{1}$$

pri čemu N označava broj jedinica promatranja, T označava broj razdoblja, x_{itk}, k=1,…K označava vrijednost k –te nezavisne varijable, i –te jedinice promatranja u t.

Parametar α je konstantni član koji je jednak za sve jedinice promatranja i ne mijenja se kroz vrijeme, $\beta_1, \beta_2,\ldots, \beta_K$ su parametri koj treba procijeniti. Slijedom toga, ε_{it} je greška relacije i-te jedinice promatranja u razdoblju t i pretpostavlja se da su ε_{it} nezavisno i identično distribuirane slučajne varijable po jedinicama promatranja i vremenu sa sredinom 0 i varijancom σ^2_ε. Uz to se pretpostavlja da su svi x_{itk} nezavisni sa ε_{it} za sve i, t, k.

Kako bi *OLS procjenitelj* bio nepristran, konzistentan i efikasan nužno je zadovoljiti iduće uvjete:

$$IID(0, \sigma^2_\varepsilon), Cov(y_{it}, y_{js}) = Cov(\varepsilon_{it}, \varepsilon_{js}) = 0; \tag{2}$$

$$\forall i, j = 1,2,..., N, \forall t, s = 1,2,...,T, t \neq s; \tag{3}$$

$$E(x_{it}\varepsilon_{it}) = 0; \tag{4}$$

Iako izgleda najjednostavnije, združeni model ima i najviše ograničenja. Prema Škrabić Perić (2012) s obzirom da se u panel podacima, podaci o jednoj jedinici promatranja ponavljaju kroz više razdoblja gotovo je nemoguće očekivati međusobnu nekoreliranost grešaka relacije u različitim razdobljima. Nadalje, nemoguće je očekivati i nekoreliranost grešaka relacije i nezavisnih varijabli. Stoga autorica zaključuje kako bi ovaj model bio prikladan za procjenu kada podaci za jednu zemlju kroz vrijeme ne bi bili korelirani. U suprotnom primjena združenog modela vodi pristranim i nekonzistentnim procjenama. Standardne greške kod združenog modela su podcijenjene jer zanemaruju pozitivnu korelaciju između jedinica promatranja odnosno *t-vrijednosti* su precijenjene, a *p-vrijednosti* su podcijenjene što znači kako se neke varijable mogu pokazati statistički značajnima u modelu iako to nisu.

Združeni model, uz sve svoje nedostatke, može poslužiti kao dobra osnova za uvod u panel analizu te se iz njega transformacijom mogu dobiti puno napredniji modeli.

4.2.2 Model između jedinica promatranja

Združeni model se ponekad transformira na način da se izračuna prosječna vrijednost opažanja za svaku jedinicu promatranja:

$$\bar{y}_i = \frac{\sum_{t=1}^{T} y_{it}}{T}, \bar{x}_{ik} = \frac{\sum_{t=1}^{T} x_{itk}}{T}, \bar{\varepsilon}_i = \frac{\sum_{t=1}^{T} \varepsilon_{it}}{T}; \qquad i = 1,...,N; k = 1,...,K; \tag{5}$$

pri čemu $\bar{y}_i$ označava prosječnu vrijednost zavisne varijable *i*-te jedinice promatranja, $\bar{x}_{ik}$ prosječnu vrijednost *k*-te nezavisne varijable, *i*-te jedinice promatranja, a $\bar{\varepsilon}_i$ prosječnu vrijednost greške relacije *i*-te jedinice promatranja. Kada se dobivene vrijednosti uvrste u jednadžbu združenog OLS modela, transformirani model koji se procjenjuje poprima oblik:

$$\bar{y}_i = \alpha + \beta_1 \cdot \bar{x}_{i1} + \beta_2 \cdot \bar{x}_{i2} + ... + \beta_k \cdot \bar{x}_{iK} + \bar{\varepsilon}_i; \qquad i = 1,...,N; \tag{6}$$

Ovakav model naziva se model „između“ jedinica promatranja (engl. Between model). Procjenitelj parametara modela se naziva procjenitelj „između“ jedinica (engl. Between estimators). Procjenitelji ovog modela su konzistentni, ali nisu efikasni. Mogu procijeniti utjecaj varijabli koje nisu promjenjive kroz vrijeme, ali gubi se na preciznosti rezultata jer se uprosječivanjem podataka gubi vremenska komponenta te procijenjeni parametri nisu realni. Model između jedinica posebice nije primjenjiv za podatke koji sadrže varijable koje su izrazito promjenjive kroz vrijeme i imaju dugu vremensku komponentu. Zaključuje se kako je ovaj model kao i združeni dobra osnova za izvođenje formula za složenije procjenitelje.

4.2.3 Model s fiksnim efektom

Model s fiksnim efektom je jednostavni linearni model u kojem se konstantni član mijenja sa svakom jedinicom promatranja pri čemu je konstantan u vremenu, a definira se kao:

$$y_{it} = \alpha_i + \beta_1 \cdot x_{it1} + \beta_2 \cdot x_{it2} + ... + \beta_K \cdot x_{itK} + \varepsilon_{it}; \qquad i = 1,...,N; t = 1,...,T; \tag{7}$$

pri čemu *N* označava broj jedinica promatranja, T broj razdoblja, x_{itk}, $k=1,\ldots,K$ vrijednost *k*-te nezavisne varijable, *i*-te jedinice promatranja u razdoblju *t*. Parametar α_i jest konstantni član različit za svaku jedinicu promatranja, a $\beta_1, \beta_2, \ldots, \beta_K$ parametri koje treba procijeniti. Parametar ε_{it} označava grešku procjene *i*-te jedinice promatranja u trenutku *t* pri čemu se

pretpostavlja da su ε_{it} nezavisno i identično distribuirane slučajne varijable po jedinicama promatranja i vremenu, sa sredinom 0 i varijancom σ^2_{ε} . Uz to, pretpostavlja se da su svi x_{itk} nezavisni s ε_{it} za sve *i, t, k.*

Model s fiksnim efektom se može formulirati pomoću dummy varijabli na idući način:

$$y_{it} = \sum_{j=1}^{N} a_j \cdot d_{ij} + \beta_1 \cdot x_{it2} + ... + \beta_K \cdot x_{itK} + \varepsilon_{it}; \qquad i = 1,...,N; t = 1,...,T; \tag{8}$$

pri čemu je d_{ij}=1 ako je i=j, a inače je d_{ij}=0. Na osnovi formule se zaključuje da je za procjenu *modela s fiksnim efektom* potrebno procijeniti N parametara $\alpha_1, \alpha_2,\ldots,\alpha_n$ uz N dummy varijabli. Nasuprot združenom modelu koji je imao jedan zajednički konstantni član za sve jedinice promatranja, model s fiksnim efektom sadrži N različitih konstantnih članova, po jedan za svaku jedinicu promatranja. Zaključuje se da je za model s fiksnim efektom nužno procijeniti *N-1* parametar više nego za združeni model. Metoda najmanjih kvadrata za procjenu modela s fiksnim efektom naziva se metodom najmanjih kvadrata s dummy varijablama (engl. Least Square Dummy Variables, LSDV).

Svojstva procjenitelja se mijenjaju s obzirom na veličinu uzorka tj. s obzirom na broj razdoblja i broj jedinica promatranja u uzorku. Kada broj razdoblja teži u beskonačnost $T \to \infty$ procjenitelj fiksnog efekta za svaku jedinicu promatranja postaje konzistentan. Ako je broj razdoblja T fiksan, a broj jedinica teži u beskonačno $N \to \infty$, procjenitelji parametara $\beta_1, \beta_2,\ldots,$ β_K postaju konzistentni, dok povećanje broja jedinica promatranja ne poboljšava svojstva procjenitelja parametara $\alpha_1, \alpha_2,\ldots,\alpha_N$. Dodavanjem novih jedinica u uzorak, bez dodavanja novih razdoblja neće se poboljšati procjena fiksnog efekta za svaku jedinicu promatranja.
Gubitak velikog broja stupnjeva slobode zbog procjene konstantnog člana za svaku jedinicu promatranja, pojava multikolinearnosti između nezavisnih varijabli zbog velikog broja dummy varijabli, nemogućnost procjene velikog broja jedinica promatranja te nemogućnost korištenja ukoliko postoje varijable koje ne ovise o vremenu kao što su npr. spol, rasa, religija i slično glavni su nedostatci ove metode. Zbog prethodno navedenih razloga javlja se potreba za definiranjem jednostavnije modela na temelju kojeg će se procjenjivati parametri $\beta_1, \beta_2,\ldots,$ β_K modela s fiksnim efektom. Tim jednostavnijim modelom potrebno je eliminirati pojedinačne efekte α_1. Škrabić Perić (2012) u svom radu detaljno analizira i obrazlaže model s transformacijama „unutar“ jedinica promatranja koji se koristi u praksi.

Opravdanost korištenja modela s fiksnim efektom testira se pomoću uobičajenog F-testa. Ispituje se nulta hipoteza o jednakosti konstantnih članova za sve jedinice promatranja. Ukoliko rezultati testa pokazuju da se nulta hipoteza ne odbacuje, zaključuje se da model s fiksnim efektom nije adekvatan u procjeni. Stoga se upućuje na korištenje jednostavnog združenog modela koji ima jednaki konstantni član za sve jedince promatranja. S druge strane, odbacivanjem nulte hipoteze, zaključuje se da je upotreba modela s fiksnim efektom opravdana u procjeni parametara definiranog modela.

4.2.4 Model s slučajnim efektom

Model sa slučajnim efektom podrazumijeva jednostavni linearni model u kojem vrijede pretpostavke da su jedinice promatranja odabrane na slučajan način te da su razlike između jedinica promatranja slučajne. Sukladno tome, *model sa slučajnim efektom* se može izraziti:

$$y_{it} = \mu + \beta_1 \cdot x_{it1} + \beta_2 \cdot x_{it2} + ... + \beta_{K1} \cdot x_{itK} + \alpha_i + \varepsilon_{it}; \qquad i = 1,..., N; t = 1,..., T; \tag{9}$$

pri čemu μ označava zajednički konstantni član za sve jedinice promatranja, a α_i slučajni efekt za svaku jedinicu promatranja. Pri tom se u ovom modelu pretpostavlja da su α_i nezavisno i identično distribuirane slučajne varijable po jedinicama promatranja sa sredinom 0 i varijancom σ^2_α, dok su $\beta_1, \beta_2, \ldots, \beta_K$ parametri koje treba procijeniti. Sljedeća pretpostavka se očituje u tome da su ε_{it} nezavisno i identično distribuirane slučajne varijable po jedinicama promatranja i vremenu, sa sredinom 0 i varijancom σ^2_ε. U nastavku, pretpostavke modela prema Baltagiju (2008, u Arnerić i Škrabić Perić, 2015) su iduće:

$$Cov(\alpha_i, x_{itk}) = 0; \qquad i = 1,2,..., N; t = 1,2,..., T; k = 1,..., K; \tag{10}$$

$$Cov(\varepsilon_{it}, x_{itk}) = 0; \qquad i = 1,2,..., N; t = 1,2,..., T; k = 1,..., K; \tag{11}$$

te da je:

$$Cov(\alpha_i, \varepsilon_{it}) = 0; \qquad i = 1,2,..., N; t = 1,..., T; \tag{12}$$

Uvodi se element v_{it} koji označava grešku relacije sastavljene od dva člana, odnosno od pojedinačne komponente α_i i specifične komponente ε_{it}, a izražava se kao zbroj:

$$v_{it} = \alpha_i + \varepsilon_{it}; \qquad i = 1,..., N; t = 1,..., T; \tag{13}$$

Budući da su α_i i ε_{it} međusobno nezavisne slučajne varijable, varijanca od v_{it} je homoskedastična pri čemu vrijedi da je jednaka:

$$Var(v_{it}) = \alpha_\alpha^2 + \alpha_\varepsilon^2; \qquad i = 1,...,N; t = 1,...,T; \tag{14}$$

Elementi matrice varijance i kovarijance su:

$$Cov(v_{it}, v_{js}) = \begin{cases} \sigma_\alpha^2 + \sigma_\varepsilon^2 & \text{za } i = j,\ t = s \\ \sigma_\alpha^2 & \text{za } i = j,\ t \neq s \\ 0 & \text{inače.} \end{cases} \tag{15}$$

Na osnovi formule o kovarijancama grešaka relacije proizlazi zaključak da postoji korelacija među greškama relacije iste jedinice promatranja *i* u različitim vremenskim točkama *t* i *s, t* ≠ *s* s koeficijentom korelacije, odnosno:

$$\rho = corr(v_{it}, v_{is}) = \begin{cases} 1 & \text{za } i = j,\ t = s \\ \dfrac{\sigma_\alpha^2}{\sigma_\alpha^2 + \sigma_\varepsilon^2} & \text{za } i = j,\ t \neq s \\ 0 & \text{inače.} \end{cases} \tag{16}$$

Nastavljajući se na prethodno razmatranja može se zaključiti da OLS nije primjerena metoda procjene parametara sa slučajnim efektom. Iz tog razloga koristi se generalizirana metoda najmanjih kvadrata (engl. Generalized Least Squares Method, GLS) koja je neosjetljiva na problem korelacije grešaka relacije iste jedince promatranja u različitim vremenskim točkama. GLS transformacijama se uklanja korelacija među greškama relacije iste jedinice promatranja. Prvim korakom se definira parametar koji poprima vrijednost između 0 i 1:

$$\theta = 1 - \left[\frac{\sigma_\varepsilon^2}{\sigma_\varepsilon^2 + T\sigma_\alpha^2} \right]^{\frac{1}{2}} \tag{17}$$

Slijedi korak u kojem se za svaku jedinicu promatranja *i* određuje prosječna vrijednost varijabli. Model koji nastaje uvrštavanjem prosječnih vrijednosti varijabli u regresijsku jednadžbu zove se model „između jedinica promatranja:

$$\bar{y}_i = \mu + \beta_1 \cdot \bar{x}_{i1} + \beta_2 \cdot \bar{x}_{i2} + ... + \beta_K \cdot \bar{x}_{iK} + \bar{v}_i; \qquad i = 1,...,N; \tag{18}$$

Oduzme li se od jednadžbe modela sa slučajnim efektom jednadžba modela „između jedinica promatranja“, pomnožena s θ i grupiraju li se članovi uz parametre μ, β_1, β_2,…, β_K dobiva se sljedeća jednadžba:

$$y_{it} - \theta \cdot \bar{y}_i = \mu \cdot (1-\theta) + \beta_1 \cdot (x_{it1} - \theta \cdot \bar{x}_{i1}) + \beta_2 \cdot (x_{it2} - \theta \cdot \bar{x}_{i2}) + ... + \beta_K \cdot (x_{itK} - \theta \cdot \bar{x}_{iK}) +$$
$$+ (v_{it} - \theta \cdot \bar{v}_i); \qquad i = 1,..., N;$$

(19)

Prethodno definirani model jednadžbom (19) procjenjuje se metodom najmanjih kvadrata. Iz čega proizlazi da je GLS procjenitelj parametara modela sa slučajnim efektom jednostavni OLS procjenitelj transformiranog modela definiranog jednadžbom (19). Nadalje, greške transformiranog modela definiranog jednadžbom su nekorelirane te su zbog toga relacije procjene dobivene OLS metodom nepristrane. Glavna svojstva GLS procjenitelja su njegova konzistentnost kada $N \to \infty$, odnosno $T \to \infty$, ili oba teže u beskonačnost. Također omogućava uvođenje varijabli koje su neovisne o vremenu ima manji gubitak stupnjeva slobode nego kod fiksnog efekta te ima manju varijancu od OLS procjenitelja.

Kako bi se testirala opravdanost korištenja modela sa slučajnim efektom provodi se test Lagrangeovoga multiplikatora (engl. Lagrange Multiplier test, LM). Pretpostavka navedenog modela je da je $E(\alpha_i) = 0$ i da je $\sigma_\alpha^2 > 0$. Ako se pokaže da je i $\sigma_\alpha^2 = 0$, slučajni efekt se može isključiti iz modela.

Nulta hipoteza pretpostavlja da je varijanca slučajnog efekta jedinica promatranja jednaka nuli. LM test kojim se testira je li varijanca slučajnih varijabli jednaka nuli je Breusch-Paganov test. Ukoliko se nulta hipoteza ne odbacuje može se zaključiti kako nema heterogenosti među jedinicama promatranja i da je korištenje modela sa slučajnim efektom nepotrebno. Suprotno, ukoliko se odbacuje nulta hipoteza zaključuje se kako je varijanca slučajnog efekta veća od nule, tj. da postoji heterogenost među jedinicama promatranja te je samim tim model sa slučajnim efektom prikladan za procjenu parametara.

4.2.5 Usporedba modela

Prilikom provođenja empirijskih istraživanja učestalo se postavlja pitanje prikladnosti određenog modela. Drugim riječima je li bolje koristiti model s fiksnim efektom ili model sa slučajnim efektom. Ne postoji jednoznačan odgovor ne postoji jer upotreba modela ovisi o prirodi podataka. U nastavku će se sukladno tome navesti prednosti svakog modela. Model sa slučajnim efektom može procijeniti utjecaj varijabli koje su neovisne o vremenu. Nadalje procjene slučajnog efekta dobivaju se GLS metodom dok se procjene fiksnog efekta dobivaju OLS metodom što u konačnici znači da će u velikim uzorcima procjene slučajnog efekta imati manju varijancu.

Model osim navedenih prednosti ima i svoje nedostatke. GLS procjenitelji parametara modela su pristrani i konzistentni ako je slučajna pogreška α_i korelirana s bilo kojom nezavisnom varijablom. Ukoliko se pojavi ovakva situacija bolje je primijeniti model s fiksnim efektom jer su procjenitelji parametara u tom modelu konzistentni bez obzira na prisutnost spomenute korelacije.

Hausmanov test se koristi pri usporedbi procijenjenih koeficijenata modela sa fiksnim efektom i modela sa slučajnim efektom. Test polazi od stajališta da su oba procjenitelja konzistentna ako ne postoji korelacija između α_i i nezavisnih varijabli x_{itk}. Ako su oba procjenitelja konzistentna, u velikim će uzorcima procjene konvergirati pravoj vrijednosti parametra. Isto tako u velikim uzorcima procjene modela s fiksnim efektom neće se značajno razlikovati od procjena modela sa slučajnim efektom. Nultom hipotezom Hausmanovog test pretpostavlja se da slučajna greška nije korelirana niti s jednom nezavisnom varijablom. Ako se nulta hipoteza ne odbaci zaključuje se procjenitelj slučajnog efekta efikasniji. S druge strane, ukoliko se odbaci nulta hipoteza zaključuje se da procjenitelj slučajnog efekta nije konzistentan, tj. upućuje se na korištenje procjenitelja fiksnog efekta.

4.3 Dinamički panel modeli

Velika većina ekonomskih relacija je dinamičke prirode što znači da sadašnja vrijednost neke varijable ovisi o prethodnim vrijednostima te varijable. Dinamički panel modeli sadržavaju zavisnu varijablu s pomakom za jedna ili više vremenski perioda unatrag ovisno o svojstvima

zavisne varijable. Modeli koji sadrži zavisnu varijablu s jednim vremenskim pomakom unatrag ima oblik:

$$y_{it} = \mu + \gamma y_{i,t-1} + \beta_1 x_{it1} + \beta_2 x_{it2} + ... + \beta_K x_{itK} + \alpha_i + \varepsilon_{it};\ i = 1,...N, t = 1,...,T$$

(21)

pri čemu se podrazumijeva da su greške relacije nezavisno i identično distribuirane slučajne varijable sa sredinom 0 i varijancom σ_ε^2 . Naime, iz jednadžbe (21) proizlazi da je y_{it} funkcija od α_i. Korelacija između zavisne varijable y_{it} i slučajnog efekta α_i će postojati bez obzira je li α_i fiksni efekt ili slučajna pogreška. Isto tako, ako se u jednadžbu (21) umjesto varijable y_{it} uvrsti varijabla $y_{i,t-1}$ dobiva se:

$$y_{i,t-1} = \mu + \gamma y_{i,t-2} + \beta_1 x_{i,t-1,1} + \beta_2 x_{i,t-1,2} + ... + \beta_K x_{i,t-1,K} + \alpha_i + \varepsilon_{i,t-1};\ i = 1,...N, t = 1,...,T \qquad (22)$$

Iz prethodno navede jednadžbe (22) proizlazi da je i $y_{i,t-1}$ funkcija od α_i. Zaključuje se kako među varijablama $y_{i,t-1}$ i α_i postoji korelacija. Kako bi se postigla pristranost i nekonzistentnost OLS procjenitelja parametara modela uočena korelacija bi se trebala zanemariti te bi se model trebao procijeniti metodom na najmanjih kvadrata.

Ako se pri procjeni modela (21) koristiti procjenitelj fiksnog efekta s transformacijom „unutar“ jedinica promatranja (engl. Within estimator), izgubit će se α_i, ali će $\left(y_{i,t-1} - \bar{y}_{i.-1}\right)$ biti korelirana s $(\varepsilon_{it} - \bar{\varepsilon}_i)$, čak i ako su ε_{it} međusobno nekorelirane slučajne varijable. Pri tome se $\bar{y}_{i.-1}$ definira formulom:

$$\bar{y}_{i.-1} = \frac{\sum_{t=2}^{T} y_{i,t-1}}{T-1} \qquad (23)$$

Korelacija između varijabli $\left(y_{i,t-1} - \bar{y}_{i.-1}\right)$ i $(\varepsilon_{it} - \bar{\varepsilon}_i)$ je prisutna zbog toga što je varijabla $y_{i,t-1}$ korelirana sa $\bar{\varepsilon}_i$.

Procjenitelji parametara modela s fiksnim efektom bit će pristrani, a faktor pristranosti jednak je $\frac{1}{T}$, dok konzistentnost ovisi o broju razdoblja *T*. Kivet (1995, u Arnerić i Škrabić Perić 2015) zaključuje ako se procjenitelj fiksnog efekta koristi za procjenu parametara modela s

velikim brojem jedinica promatranja N i fiksnim brojem razdoblja T, tada će procjene parametara modela biti pristrane i nekonzistentne. Nadalje, Kivet je predložio aproksimaciju kojom se uklanja pristranost procjenitelja fiksnog efekta s nekoreliranim greškama relacije, predloženi procjenitelj je nekoliko puta nadograđivan. Dobiveni procjenitelj bit će konzistentan ako se koriste podaci u kojima broj razdoblja teži u beskonačnost $T \to \infty$.

Procjenitelji parametara dinamičkih modela sa slučajnim efektom također su pristrani. Varijabla $\left(y_{i,t-1} - \lambda \overline{y}_{i.-1}\right)$ je korelirana s varijablom $(\varepsilon_{it} - \lambda \overline{\varepsilon}_i)$. Diferenciranje se koristi kao alternativni način transformacije dinamičkog modela kako bi se izgubio individualni efekt α_i.

Anderson i Hsiao (1981, u Arnerić i Škrabić Perić) predložili su korištenje prvih diferencija kako bi se iz modela uklonio slučajni efekt α_i. Diferenciranjem se uklanja slučajni efekt, ali ostaje problem korelacije među varijablama $\Delta y_{i,t-1} = \left(y_{i,t-1} - y_{i,t-2}\right)$ i $\Delta \varepsilon_{i,t-1} = \left(\varepsilon_{i,t-1} - \varepsilon_{i,t-2}\right)$. Nadalje, Anderson i Hsiao su predložili da se $\Delta y_{i,t-2} = \left(y_{i,t-2} - y_{i,t-3}\right)$ ili $y_{i,t-2}$ koriste kao instrumentalne varijable za $\Delta y_{i,t-1} = \left(y_{i,t-1} - y_{i,t-2}\right)$. Tako definirane varijable nisu korelirane s $\Delta \varepsilon_{i,t-1} = \left(\varepsilon_{i,t-1} - \varepsilon_{i,t-2}\right)$ ako $\varepsilon_{i,t}$ nisu međusobno korelirani. Iz prethodno navedeno može se zaključiti kako su procjenitelji dobiveni ovom metodom instrumentalnih varijabli konzistentni, al ne nužno i efikasni.

Arelleano (1989, u Arnerić i Škrabić Perić) pokazao je da za procjenu dinamičkog modela procjenitelj parametara modela koji kao instrumentalne varijable koristi diferencije $\Delta y_{i,t-2}$, umjesto varijabli s vremenskim pomakom $y_{i,t-2}$, ima veliku varijancu, što znači da nije efikasan procjenitelj.

Arellano i Bond (1991, u Arnerić, Škrabić Perić) stoga su predložili korištenje generalizirane metode momenata (engl. generalized method of moments, GMM) koja je efikasnija od Andersonove i Hsiaove metode. Poboljšanje Arellanovog i Bondovog procjenitelja predložili su Arellano i Bover (1995), a naknadno su ga nadogradili i Blundell i Bond (1998).

S obzirom kako će se u radu za analizu ekonomskih relacija koristiti isključivo statički panel modeli neće se detaljnije ulaziti u teorijsku analizu i razradu dinamičkih panel modela.

5. EMPIRIJSKA ANALIZA I REZULTATI

5.1 Definiranje uzorka

Nakon teorijskog iznošenja problematike rada te definiranja metoda rada, unutar ovog poglavlja ispitat će se prethodno postavljene istraživačke hipoteze te će se pokušati razjasniti uloga visokog obrazovanja u razvojnom putu odabranih zemalja srednje i istočne Europe tijekom razdoblja od 1993. – 2014. godine. Za dokazivanje postavljenih hipoteza odabrano je 11 zemalja srednje i istočne Europe i to su redom: Bugarska, Češka Republika, Estonija, Hrvatska, Latvija, Litva, Mađarska, Poljska, Rumunjska, Slovačka, Slovenija. Vremensko razdoblje promatranja započinje godinama u kojima su navedene zemlje napuštale komunističke režime te slijedom toga i sve obrazovne politike nametnute od strane sustava.

Prilikom uspostavljanja baze podataka koja uključuje prostornu i vremensku komponentu korišteni su dostupni web izvori. Kao primarni izvor podataka koristila se internetska stranica Svjetske banke na kojoj je dostupan veliki broj baza podataka sa različitim indikatorima. Najpopularnija baza podataka je *World Development Indicators* (The World Bank, 2015a) koja je sastavljena od službeno priznatih međunarodnih izvora. Predstavlja najnovije i najtočnije dostupne podatke razvoja koji uključuju nacionalne, regionalne te globalne procjene. Iz navedene baze podataka preuzeti su podaci o pokazateljima ekonomskog razvoja kao što su bruto domaći proizvod i bruto domaći proizvod po stanovniku koji su u radu korišteni kao zavisne varijable te podaci o populaciji, stopi fertiliteta, ulaganjima u istraživanje i razvoj, direktnim stranim investicijama i slično. Nadalje, izvor koji se koristio za prikupljanje podataka o visokom obrazovanju također je dostupan na stranicama Svjetske banke, ali pod bazom podataka koja se odnosi na obrazovanje. *Education Statistics – All Indicators* (The World Bank, 2015b) sadrži preko 2500 međunarodnih pokazatelja koji se odnose na pristup obrazovanju, napredovanje, pismenost, nastavnike, stanovništvo te izdvajanja za obrazovanje. Pokazatelji pokrivaju obrazovni ciklus od predškolske dobi do visokog obrazovanja koje je upravo krucijalno za tematiku ovog rada.

Slijedom prethodno iznesenih nalazišta definiraju se čimbenici gospodarskog rasta na koje bi obrazovanje moglo imati pozitivan i značajan utjecaj u zemljama srednje i istočne Europe. Zavisne varijabla koja će se koristiti za ispitivanje istraživačkih hipoteza su *bruto domaći proizvod* (engl. Gross domestic product) kojim je definirana vrijednost finalnih dobara i usluga proizvedenih unutar neke zemlje u lokalnoj valuti, odnosno *bruto domaći proizvod po*

stanovniku (engl. Gross domestic product per capita) koji je izračunat dijeljenjem GDP-a s brojem stanovnika u pripadajućoj zemlji te je izražen u američkim dolarima. Nadalje kao zavisna varijabla za istraživačku hipotezu III koristit će se i *bruto omjer upisanih u visoko obrazovanje* (engl. Gross enrolment ratio, tertiary, both sexes) koji se odnosi na omjer ukupnog upisa populacije, bez obzira na godine, u visoko obrazovanje. Sukladno problematici rada i prethodno definiranim istraživačkim hipotezama definiraju se čimbenici razmatrani u analizi s pripadajućom metodologijom izrade. Među izdvajanjima odnosno ulaganjima države u visokoobrazovni sektor određuju se dvije varijable, *državna izdvajanja za visoko obrazovanje kao % cjelokupnog državnog izdvajanja za obrazovanje* (engl. Expenditure on tertiary as % of government expenditure on education) te *državna izdvajanja po studentu kao % bruto domaćeg proizvoda po stanovniku* (engl. Government expenditure per tertiary student as % of GDP per capita). Navedene varijable su temeljne i krucijalne za dokazivanje postojanja veze između ulaganja u visoko obrazovanje i ekonomskog rasta te na njima počiva problematika ovoga rada. Nadalje iz okoline obrazovanog sustava odabrane su varijable koje bi prema pretpostavkama autora trebale imati pozitivan i značajan utjecaj i to su *visokoobrazovana radna snaga kao % ukupne radne snage* (engl. Labor force with tertiary education, % of total), *neto priljev direktnih stranih investicija kao % od bruto domaćeg proizvoda* (engl. Foreign direct investment, net inflows, % of GDP), *izdvajanja za istraživanje i razvoj kao % od bruto domaćeg proizvoda* (engl. Research and development expenditure % of GDP), *godišnji porast broja stanovnika izražen u %* (engl. Population growth, annual %), *stopa fertiliteta* (engl. Fertility rate, total; births per woman), *ukupna nezaposlenost izražena kao % od ukupne radne snage* (engl. Unemployment, total; % of total labor force) te *državna izdvajanja za primarno obrazovanje kao % cjelokupnog državnog izdvajanja za obrazovanje* (engl. Expenditure on primary as % of government expenditure on education) i *državna izdvajanja za sekundarno obrazovanje kao % cjelokupnog državnog izdvajanja za obrazovanje* (engl. Expenditure on secondary as % of government expenditure on education) koje su za potrebe istraživanja u procesu analize spojene te je formirana jedna zajednička varijabla koja će definirati zajednički utjecaj primarnog i sekundarnog obrazovanja. Također definirane su i varijable korištene u modelu prema Keller (2006) i to redom *inflacija, potrošačke cijene* (engl. Inflation, consumer prices, annual %), *GINI koeficijent, državna izdvajanja za obrazovanje kao % GDP-a* (engl. Government expenditure on education as % of GDP) te *otvorenost ekonomije* izračunata kao zbroj uvoza i izvoza dobara i usluga kao postotka GDP-a (engl. Export of goods and services + Import of goods and services % of GDP) U nastavku rada definirat će i teorijski obrazložiti ekonomski model na temelju kojeg

će se provoditi daljnja analiza te će se dati tablični prikaz imena varijabli te njihove skraćenice koje su korištene prilikom analize.

Tablica 1: Opis i prikaz varijabli

Varijable s pripadajućim oznakama korištenima u istraživanju - *hrvatski*	Varijable s pripadajućim oznakama korištenima u istraživanju - *engleski*	Oznake varijabli
Bruto domaći proizvod	*Gross domestic product*	GDP
Bruto domaći proizvod po stanovniku	*Gross domestic product per capita*	GDPPC
Bruto omjer upisanih u visoko obrazovanje	*Gross enrolment ratio, tertiary, both sexes*	ENRTER
Državna izdvajanja za visoko obrazovanje kao % cjelokupnog državnog izdvajanja za obrazovanje	*Expenditure on tertiary as % of government expenditure on education*	EXPTER
Državna izdvajanja po studentu kao % bruto domaćeg proizvoda po stanovniku	*Government expenditure per tertiary student as % of GDP per capita*	EXPTERS
Visokoobrazovana radna snaga kao % ukupne radne snage	*Labor force with tertiary education, % of total*	LFTER
Neto priljev direktnih stranih investicija kao % od bruto domaćeg proizvoda	*Foreign direct investment, net inflows, % of GDP*	FDI
Izdvajanja za istraživanje i razvoj kao % od bruto domaćeg proizvoda	*Research and development expenditure % of GDP*	RD
Godišnji porast broja stanovnika izražen u %	*Population growth, annual %*	POP
Stopa fertiliteta	*Fertility rate, total; births per woman*	FER
Ukupna nezaposlenost izražena kao % od ukupne radne snage	*Unemployment, total; % of total labor force*	UNEMP
Državna izdvajanja za primarno+ sekundarno obrazovanje kao % cjelokupnog državnog izdvajanja za obrazovanje	*Expenditure on primary as % of government expenditure on education* *Expenditure on secondary as % of government expenditure on education*	PRIMSEC
Inflacija, potrošačke cijene	*Inflation, consumer prices (annual %)*	CPI
GINI koeficijent	*GINI index (World Bank estimate)*	GINI
Državna izdvajanja za obrazovanje kao % GDP-a	*Government expenditure on education as % of GDP (%)*	GOVEXP
Otvorenost ekonomije	*Exports of goods and services (% of GDP) + Imports of goods and services (% of GDP)*	OPE

Izvor: izrada autora

5.2 Oblikovanje ekonomskog modela[8]

Neoklasični model rasta, koji je dao nekoliko značajnih doprinosa ekonomskoj teoriji, a ujedno označio napredak u izgradnji modela rasta, formulirao je Robert Solow 1956. godine. Kroz pojednostavljene pretpostavke i jednostavne funkcionalne oblike, Solow je ukazao na elemente tehnologije, kapitala i rada kao ključne elemente o kojima se treba razmišljati kada

[8] Preuzeto iz Krueger, D. (2009): Makroekonomika, Katedra za ekonomiju Sveučilište u Pennsylvaniji

se govori o dugoročnom ekonomskom rastu. Solow kao osnovnu pretpostavku svog modela, iz koje proizlaze svi glavni zaključci, navodi opadajući prinos faktora proizvodnje.

Temeljne pretpostavke Solowljeva modela tiču se prirode proizvodnje, međunarodne razmjene, države i zaposlenosti. Model pretpostavlja da se u gospodarstvu proizvodi samo jedno dobro. Pretpostavlja se da nema međunarodne razmjene iz razloga što je navedeni model zatvorenog gospodarstva. Pretpostavlja se, nadalje, da nema države. Na koncu se pretpostavlja puna zaposlenost svih faktora proizvodnje (rada i kapitala). Model se sastoji od dvije osnovne jednadžbe. Prva je *neoklasična funkcija agregatne proizvodnje*, a druga *jednadžba akumulacije kapitala*:

$$Y(t) = F(K(t), L(t)) \tag{24}$$

U jednadžbi je Y (t) ukupna razina proizvodnje u vremenu t. Output se proizvodi s dva inputa: kapitalom K(t) i radom L(t). Pretpostavljene su ove karakteristike funkcije F:

- Ima konstantne prinose obujma: ako se oba inputa udvostruče, onda će se udvostručiti i output
- Postoje pozitivni prinosi koji su opadajući. Ako jedan input ostaje nepromijenjen, povećanjem drugoga poveća se proizvodnja ali uz padajuće prinose

$$K(t) = sY(t) - \delta K(t) \tag{25}$$

Promjena kapitala u razdoblju *t* je *K(t)* i ta promjena je određena ukupnim investicijama u razdoblju *t, sY (t),* i smanjenjem kapitala uzrokovanom amortizacijom *δK(t)* gdje je *s* udio štednje u proizvodnji u razdoblju t. To je onaj dio dohotka koji nije potrošen.Tijekom vremena mnogi autori su pokušali ukloniti nedostatke Solowljevog modela te su ga modificirali na razne načine (Ramsyjev model, Lucasov model, Romer-Lucasov model, Model cirkularne i kumulativne uzročnosti: Myrdal i Kaldor). Za dokazivanje postavljenih hipoteza procjenjivat će se Lucasov model endogenog rasta (1988) koji u model uključuje ljudski kapital. Prema Lucasu (1988) inputi znanja imaju važnu ulogu u ekonomskokom rastu, međutim njegov fokus je na razini ljudskog kapitala Pretpostavka je da radnici provode dio svog vremena za stjecanje ljudskog kapitala (H) učeći kroz rad. Nadalje, pretpostavlja se da ljudski kapital povećava produktivnost pojedinih radnika. Lucas pretpostavlja da postoji interni efekt, *H*, i eksterni efekt, *J*, od kojeg koristi imaju svi radnici. Ovo implicira da se dani broj jedinica rada rastućeg ljudskog kapitala može tretirati kao ekvivalent rastućeg broja

jedinica ljudskog kapitala fiksne efikasnosti i kvalitete. Model zaključuje da dio rasta outputa, koji se u Solowljevom neoklasičnom modelu rasta tretira kao tehnološki rezidual, ovdje se u potpunosti pripisuje radu kroz stjecanje ljudskog kapitala. Centralno u Romerovom i Lucasovom modelu je internaliziranje tehnološkog napretka unutar neoklasične proizvodne funkcije uvodeći znanje kao eksplicitni faktor proizvodnje. U Solowljevom modelu rasta, tehnologija je „mana s neba“ koja rezultira pomakom agregatne funkcije proizvodnje prema gore. Za razliku od toga, endogene teorije rasta teže identifikaciji mehanizama koji objašnjavaju tehnološki napredak u vremenu i da pokažu da je on proizvod internih procesa u gospodarstvu. Novi teoretičari rasta su propitkivali ideju da je akumuliranje kapitala ključno za rast, zato što je fizički kapital podložan zakonu opadajućih prinosa. Nove teorije rasta pretpostavljaju da, za razliku od fizičkog kapitala, postoje rastući prinosi na znanje. Ključna karakteristika rastućih prinosa na znanja je nesuparništvo, odnosno aspekt javnog dobra.

Nakon teorijske definicije odabranog ekonomskog modela navest će se primjeri dosadašnjih radova sa korištenjem sličnih modela i metoda istraživanja. Hansen i Knowles (1998, u Požega i Crnković, 2008) u svom istraživanju OECD zemalja svijeta prema podacima iz vremenskog razdoblja od 1960. do 1985. godine pokušali su otkriti koliko je ekonomski rast neke zemlje posljedica akumulacije fizičkog i ljudskog kapitala. U svojim su analizama koristili model standardne proizvodne funkcije u kojem ukupna zaposlenost nije u srazmjeru s tržištem ljudskog kapitala. Proizvodna funkcija je: $Y=f(A, K, L_1, L_2, L_3)$ gdje je Y – ukupni *output*, A – parametar tehnologije, K – fizički kapital, L_1 – radnici sa završenom osnovnom školom, L_2 – radnici sa završenom srednjom školom, a L_3 – radnici sa završenim fakultetom. Rezultati istraživanja pokazali su kako akumulacija fizičkoga kapitala ima interne i eksterne efekte na proces proizvodnje na način da povećava tehnička znanja u ekonomiji, što dovodi do povećane produktivnosti gospodarskih subjekata, a što je u skladu sa znanstvenim otkrićima Romera (2004) u vezi s tematikom akumulacije fizičkog kapitala. Također je analiza pokazala kako broj radnika sa završenim fakultetom ima manji utjecaj na proizvodni *output* od broja radnika sa završenom srednjom školom, što se može objasniti činjenicom kako je radna snaga u posljednjoj promatranoj godini (1985. godina) mnogo veća (u prosjeku oko 300 posto) od radne snage u prvoj promatranoj godini (1960. godina) za sve zemlje svijeta promatrane u analizi. Sukladno izloženim zaključcima navedenog rada, a koji se odnose na tvrdnje kako broj radnika sa završenom srednjom školom ima veći utjecaj na proizvodni *output* od radnika sa završenim fakultetom, ovaj rad će pokušati dokazati kako visoko obrazovanje te visokoobrazovane osobe imaju veći utjecaj na ekonomski rast. Požega i

Crnković (2008) u svom radu na temelju *indeksa ljudskog razvoja, broju telefonskih linija per capita, broju pretplatnika mobilnih uređaja per capita, broju korisnika interneta per capita* te *potrošnji električne energije per capita* za 177 zemalja svijeta u razdoblju od 1975. – 2005. analiziraju utjecaje ljudskog (u radu izražen preko *indeksa ljudskog razvoja*) te fizičkog (izražen zbrojem *brojem telefonskih linija per capita, brojem pretplatnika mobilnih uređaja per capita, brojem korisnika interneta per capita* te *potrošnjom električne energije per capita*) kapitala. Rezultati do kojih su autori došli, uzevši bruto domaći proizvod po stanovniku kao zavisnu varijablu pokazuje kako varijabla ljudskog i fizičkog kapitala ima značajan i pozitivan utjecaj. Nadalje, Bond et al. (2001) formiraju model prema Solowljevom u kojem *koriste diferenciranu logaritmiranu vrijednost BDP per capita* kao zavisnu varijablu te *logaritam vrijednosti iz prethodnog razdoblja (lagirana) BDP-a per capita, logaritmiranu vrijednost stope investicija* i *logaritmiranu vrijednost stope rasta stanovništva* zbrojenu s 0.05 što definira zbroj pripadajuće egzogene *stope tehničke promjene* i *pripadajuću stopu amortizacije*.

Autori zaključuju kako stopa investicija ima pozitivan te značajan utjecaj na razinu BDP-a per capita. Nadalje u proširenom Solowljevom modelu prema Bond et al (2001), osnovne varijable ostaju iste i dodaje se varijabla *bruto omjer upisanih u sekundarno obrazovanje*, rezultati su također značajni u odnosu na početni dohodak.

Na temelju prethodno navedenih empirijskih istraživanja i modela u ovom radu će se formirati modificirani Solowljev model prema Lucasu(1988) te prošireni Solowljev model putem kojeg će se promatrati utjecaji ulaganja u visoko obrazovanje te visokog obrazovanja općenito na ekonomski rast. Rad je koncipiran na način da će se analizirati tri istraživačke hipoteze, dvije za zavisnu varijablu imaju rast *GDP-a* odnosno rast *GDPPC* koje su pokazatelji ekonomskog rasta dok će treća istraživačka hipoteza imati zavisnu varijablu *ENRTER* koja služi kao *proxy* za broj visokoobrazovane populacije. Prilikom ispitivanja svake zavisne varijable formirat će se više modela sa različitim brojem nezavisnih varijabli. U nastavku će se provesti proces deskriptivne statistike kojim se prikupljaju podaci, grupiraju te tabelarno i grafički prikazuju sve s ciljem izračunavanja različitih brojčanih pokazatelja koji izražavaju karakteristike promatrane pojave.

5.3 Deskriptivna statistika

Analizu je uobičajeno započeti deskriptivnom statistikom. U *tablici 2* prikazana je deskriptivna statistika za svaku varijablu.

Tablica 2: Deskriptivna statistika uzorka

Varijabla	*Broj opažanja*	*Aritmetička sredina*	*Standardna devijacija*	*Minimalna vrijednost*	*Maksimalna vrijednost*
Zavisne varijable korištene u istraživanju					
GDP[9]	**232**	**22000000**	**6070000**	**299**	**32200000**
GDPPC	**232**	**9292,37**	**6047,061**	**1148,494**	**27501,81**
ENRTER	**228**	**49,03**	**19,58**	**11,72**	**88,468**
Ulaganje u obrazovanje					
EXPTER	134	20,44	3,1	13,45	28,47
EXPTERS	139	23,57	5,61	12,09	41,92
PRIMSEC	112	64,06	4,77	49,96	72,73
Ostala ulaganja					
FDI	231	4,82	5,95	-16,09	50,78
RD	193	0,84	0,44	0,32	2,59
Ostale zavisne varijable					
FER	231	1,39	0,15	1,09	1,87
LFTER	217	21,48	8,53	8,1	44
POP	238	-0,4	0,74	-3,82	3,73
UNEMP	242	10,63	4	3,9	21,4

Izvor: izrada autora, The World Bank (2015a; 2015b)

Prethodno procijenjene vrijednosti varijable *GDP-a* pokazuju kako prosječna vrijednost za zemlje srednje i istočne Europe iznosi 22 000 000 mil. USD dok je maksimalna vrijednost iznosila 32 200 000 mil. USD, a minimalna 299 mil. USD. Na temelju rezultata deskriptivne statistike može se zaključiti kako je prosječni *GDPPC* za promatrane zemlje iznosio 9292,37 USD dok je maksimalna vrijednost iznosila 27501,81 USD te 1148,49 USD minimalna vrijednost. Nadalje, prosječan *bruto omjer upisanih u visoko obrazovanje* iznosi 49,03% s prosječnim odstupanjem od prosjeka koje iznosi 19,58 postotnih poena. Maksimalan bruto omjer upisanih u visoko obrazovanje iznosi 88,47%. Ulaganje u obrazovanje promatra se kroz dvije varijable *EXPTER*, *EXPTERS* koje su prethodno definirane. Prosječni iznos ulaganja u visoko obrazovanje kao postotka državne potrošnje za obrazovanje odnosno *EXPTER* iznosi 20,44% s prosječnim odstupanjem od prosjeka koje iznosi 3,1 postotnih poena, 13,44% kao minimalna vrijednost te 28,475% kao maksimalnom vrijednosti. Prosječna državna ulaganja po studentu, *EXPTERS* iznose 23,57% s prosječnim odstupanjem od 5,61 postotnih poena. Minimalna vrijednost varijable *EXPTERS* iznosi 12,09%, a maksimalna 41,92%. Varijabla *PRIMSEC* u uzorku iznosi 64,06% uz prosječno odstupanje od 4,77 p.p., minimalnu

[9] Vrijednosti izražena u milijunima USD

vrijednost 49,96% te maksimalnu 72,73%. Od ostalih ulaganja izdvajaju se direktne strane investicije, *FDI* koje u prosjeku iznose 4,82% s prosječnim odstupanjem u iznosu 5,95 postotnih poena te ulaganja u istraživanje i razvoj, *RD* koja u prosjeku iznose 0,84% dok prosječno odstupanje iznosi 0,43 p.p. Nadalje, varijabla *FER* u prosjeku iznosi 1,39 s prosječnim odstupanjem od 0,15 postotnih poena minimalnom i maksimalnom vrijednosti u iznosu od 1,09 odnosno 1,87. Prosječan iznos *radne snage s visokom obrazovanje*, *LFTER* unutar ukupne radne snage iznosi 21,48% uz odstupanje od 8,53 p.p. te minimalnom i maksimalnom vrijednosti u iznosu od 8,1% odnosno 44%. Prosječna vrijednost godišnjeg rasta stanovništva, *POP* je negativna i iznosi -0,4% s prosječnim odstupanje od 0,74 p.p. minimalnom vrijednosti u iznosu od -3,82 te maksimalnom vrijednosti od 3,73%. Nezaposlenost, *UNEMP* od ukupne radne snaga u uzorku iznosi 10,63% s prosječnim odstupanjem od 4 p.p., minimalnom vrijednosti 3,9% te maksimalnom od 21%. Na temelju prethodno procijenjenih rezultata može se zaključiti kako postoji veliki razlika između minimalne i maksimalne vrijednosti *bruto omjera upisanih u visoko obrazovanje* u zemljama srednje i istočne Europe koja se kreće od 11,72% (Rumunjska, 1993. godine) do 88,45% (Slovenija, 2010. godine). Dobivene vrijednosti u skladu su s teorijskim pretpostavkama kojima se tvrdi da je *bruto omjer upisanih u visoko obrazovanje* bio nizak u početnim godinama tranzicijskog razdoblja te je rastao sa stabilizacijom zemlje.

5.4 Testiranje ekonomskog modela

Unutar ovog dijela rada sadržani su rezultati provedene panel analize. Za provođenje panel analize koristit će se statički panel model. Sama specifikacija modela u kojoj je zavisna varijabla rast *GDP-a* i rast *GDPPC-a* ne zahtjeva korištenje dinamičkih panel modela.

Važno je naglasiti kako će se prilikom svih procjena testirati tri modela statičkih panela (*združeni*, s *fiksnim* te sa *slučajnim efektom*) te će se na temelju pripadajućih testova odlučiti koji model je najbolji.

Neposredno prije formiranja ekonometrijskog modela potrebno je ispitati međusobnu korelaciju između promatranih nezavisnih varijabli kako bi se otkrio mogući problem

multikolinearnosti koji može uzrokovati poremećaj pri procjeni vrijednosti parametara, njihove značajnosti te smjera utjecaja na zavisnu varijablu. Prema dosadašnjim saznanjima primjereni test za otkrivanje multikolionearnosti u panel modelima ne postoji. Prema Baltagi et al. (2009, u Škrabić Perić 2012) u empirijskim radovima koji koriste panel modele za uočavanje problema multikolinearnosti koriste se koeficijenti korelacije između parova potencijalnih nezavisnih varijabli.

Tablica 3: Korelacijska matrica između parova nezavisnih varijabli dok se *GDP* i *GDPPC* promatraju kao zavisne varijable

	LGDP	**LGDPPC**	LEXPTER	LENRTER	LEXPTERS	LLFTER	LFDI	LRD	LPOP
LGDP	1								
LGDPPC		1							
LEXPTER	0,2398	0,4901	1						
LENRTER	0,0044	0,6710	0,138	1					
LEXPTERS	0,3291	-0,0903	0,353	**-0,5932***	1				
LLFTER	-0,314	0,3138	-0,039	**0,5569***	-0,407	1			
LFDI	0,2510	-0,0043	-0,167	0,1226	0,115	-0,0018	1		
LRD	0,2351	0,6535	0,432	0,2899	0,299	0,220	-0,204	1	
POP	0,2839	0,2292	0,3209	-0,0842	0,2808	0,2620	-0,125	0,428	1

* se označava statistička značajnost na razini od 5%; istaknute vrijednosti upućuju na korelaciju iznad 0,5
Izvor: izrada autora

Nakon provođenja testa korelacije može se uočiti koji bi parovi nezavisnih varijabli mogli uzrokovati problem multikolinearnosti. Unutar matrice uočena je srednje jaka pozitivna korelacija u iznosu od 0,5569 između *bruto omjera upisanih u visoko obrazovanje* (LENRTER) te *visokoobrazovane radne snage* (LLFTER) iz čega se zaključuje kako bi istovremeno uvrštavanje promatranih varijabli moglo voditi problemu multikolinearnosti. Također uočen je i koeficijent korelacije od -0,5932 između *bruto omjera upisanih u visoko obrazovanje* (LENRTER) te *državnih izdvajanja po studentu* (LEXPTERS). Koeficijent definira srednje jaku negativnu korelaciju te sugerira kako bi istodobno uvrštavanje obje varijable u model moglo prouzročiti problem multikolinearnosti. Prilikom formiranja ekonometrijskog modela važno je pažljivije promatrati prethodno navedene parove nezavisnih varijabli te provjeriti hoće li njihovo istovremeno uvrštavanje dovesti do problema multikolinearnosti. Ostale vrijednosti koeficijenata korelacije nisu na razini koja bi mogla dovesti do problema multikolinearnosti. Imajući u vidu kako se ispitivane matrice koeficijenata korelacije razlikuju samo prema zavisnoj varijabli u modelu možemo uočiti

slične odnosno identične koeficijente. U nastavku je prikazana korelacijska matrica između parova nezavisnih varijabli za model preuzet iz istraživanja prema Keller (2006).

Tablica 4: Korelacijska matrica između parova nezavisnih varijabli dok se *GDP* i *GDPPC* promatraju kao zavisna varijabla za model prema Keller (2006)

	LGDP	LGDPPC	LEXPTER	LCPI	LGOVEXP	LOPE	LFER	LGINI
LGDP	1							
LGDPPC		1						
LEXPTER	0.2398	0.4901	1					
LCPI	-0.2103	-0.6218	-0.1152	1				
LGOVEXP	-0.1245	0.1736	-0.1183	-0.1528	1			
LOPE	-0.0144	0.5814	0.2489	-0.3675	0.0987	1		
LFER	-0.0180	0.2376	0.2659	0.0606	0.0708	-0.0349	1	
LGINI	-0.3179	-0.1908	-0.4774	-0.0174	0.3043	-0.1890	0.0062	1

* se označava statistička značajnost na razini od 5%; istaknute vrijednosti upućuju na korelaciju iznad 0,5
Izvor: izrada autora

Korelacijska matrica izložena za model prema Keller (2006) upućuje na to kako između gotovo svih parova varijabli postoji slaba korelacija. Stoga se može zaključiti kako promatrani parovi nezavisnih varijabli vjerojatno neće uzrokovati problem multikolinearnosti u ekonometrijskom modelu.

Osnovni model značaja visokog obrazovanja kojim se polazi u ispitivanje postavljenih istraživačkih hipoteza formiran je prema modificiranom *Solowljevom modelu prema Lucasu (1988)* te se sastoji od skupine varijabli fizičkog kapitala i ljudskog kapitala. Model će se u daljnjoj razradi promatrati kroz više različitih specifikacija. Osnovni model prikazan je u nastavku:

$$\Delta y_{it} = \gamma \cdot \log y_{i,t-1} + \beta_1 \cdot \log K_{it} + \beta_2 \cdot \log L_{it} + \varepsilon_{it}; \qquad i = 1,...,11; t = 1,...,22; \qquad (26)$$

pri čemu Δy_{it} definira *output*, odnosno gospodarski rast te će se za navedenu varijablu koristiti dva pokazatelja, rast *GDP-a* i rast *GDPPC-a,* odnosno njihove diferencirane vrijednosti. Model uključuje i varijable *GDP-a* i *GDPPC-a* iz prethodnog razdoblja budući da je *bruto domaći proizvod* odnosno *bruto domaći proizvod po stanovniku* pojava čija vrijednost u promatranom razdoblju ovisi o vrijednostima iz prethodnog razdoblja. Upravo varijabla $y_{i,\,t-1}$ definira *GDP* i *GDPPC* zemlje *i* iz prethodnog razdoblja *t-1*. Varijabla $K_{i,t}$ definira varijablu fizičkog kapitala zemlje *i* u razdoblju *t* dok varijabla $L_{i,t}$ definira varijablu ljudskog kapitala zemlje *i* razdoblju *t*. Parametri koje treba procijeniti su γ, $\beta_1, \beta_2,$ a ε_{it} grešku relacije

zemlje *i* u razdoblju *t*. Važno je napomenuti kako su sve varijable, osim varijable *POP*, logaritmirane.

U nastavku će se, na osnovi definiranog polaznog modela vršiti procjena gdje će nam diferencirana vrijednost *GDP-a* biti zavisna varijabla dok će se lagirana vrijednost *GDP*-a, ostale varijable koje predstavljaju fizički i ljudski kapital te ostale investicije promatrati kao nezavisne. Rezultati tog modela dani su u *tablici 8* kroz specifikacije modela. Za svaku specifikaciju modela provedeni su dijagnostički testovi (*F-test, LM test* i *Hausman test* po potrebi) kako bi se odredilo koji je od statističkih panel modela (*združeni, model s fiksnim efektom* ili *model sa slučajnim efektom*) najprikladniji za procjenu. U *tablici 8* dani su rezultati provedenih testova i u retku *Odabrani model* navedeno je koji je model procijenjen tj. koji je model najprikladniji. Isto tako, prema modificiranom Solowljevom modelu formirano je prvih pet modela sljedeća dva modela definiraju prošireni Solowljev model dok je posljednji model koji je preuzet iz istraživanja Keller (2006) te se njim testira samo II. hipoteza. Slijedom toga u nastavku je dan prikaz panel analize prethodno objašnjenih specifikacija model.

Tablica 5: Rezultati panel analize (*GDP*)

Varijabla	*Model 1*	*Model 2*	*Model 3*	*Model 4*	*Model 5*	*Model 6*	*Model 7*
L.LGDP	-0,165*** (0,0256)	-0,120*** (0,0260)	-0,144*** (0,0242)	-0,191*** (0,0176)	-0,270*** (0,0221)	-0,146*** (0,0245)	-0,173*** (0,0261)
Varijable fizičkog i ljudskog kapitala vezane uz visoko obrazovanje							
LEXPTER	0,160*** (0,0585)	0,167*** (0,0604)					0,181*** (0,0604)
LENRTER	0,0860* (0,0434)		0,0820* (0,0479)	0,159*** (0,0438)	0,263*** (0,0498)	0,0923* (0,0492)	0,0994** (0,0450)
LEXPTERS			-0,0318 (0,0391)			-0,0266 (0,0397)	
LLFTER		-0,00769 (0,0567)					
Ostale varijable fizičkog i ljudskog kapitala							
POP						-0,00935 (0,0137)	-0,0130 (0,0184)
LFDI				0,0374*** (0,0136)			
LRD					0,0529 (0,0458)		
Varijable korištene u istraživanju Keller (2006)							
LCPI							
LGOVEXP							
LOPE							
LGINI							
Konstanta	3,515*** (0,492)	2,698*** (0,541)	3,552*** (0,525)	4,313*** (0,338)	5,992*** (0,449)	3,554*** (0,531)	3,579*** (0,495)
F-test	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0038
LM test	0,0257	0,0304	0,0706	0,0000	0,0145	0,2611	0,3499
Hausman test	0,0000	0,0000	/	0,0000	0,0000	/	/
Odabrani model	**Fiksni efekt**	**Fiksni efekt**	**Fiksni efekt**	**Fiksni efekt**	**Fiksni efekt**	**Fiksni efekt**	**Fiksni efekt**
Broj opažanja	133	133	139	201	190	135	129
R2	0,352	0,324	0,304	0,459	0,501	0,312	0,366

, **, * označava statističku značajnost na razini 10%, 5% i 1%; vrijednosti u zagradama su t-vrijednosti*
Izvor: izrada autora

Prema procijenjeni prvog modela (*model 1*) može se zaključiti kako su parametri *L.LGDP* te *LEXPTER* na razini pouzdanosti od 99% statistički značajni te je procijenjeni smjer za *L.LGDP* negativan dok je za *LEXPTER* pozitivan, varijabla *LENRTER* je statistički značajna na razini signifikantnosti od 90% te je pozitivnog smjera. Prema tome prva kombinacija modela koji uključuje jednu varijablu *fizičkog kapitala* te jednu varijablu *ljudskog kapitala* može se definirati:

$$\Delta GDP_{it} = \gamma \cdot L.LGDP_{i,t-1} + \beta_1 \cdot LEXPTER_{it} + \beta_2 \cdot LENRTER_{it} + \varepsilon_{it}; \quad i = 1,...,11; t = 1,...,22; \quad (27)$$

Iduća specifikacija modela (*model 2*) ukazuje kako su parametri *L.LGDP* te *LEXPTER* koja predstavlja *fizički kapital*, tj. *državna izdvajanja za visoko obrazovanje* na razini pouzdanosti od 99% također statistički značajni dok se varijabla *LLFTER* koja predstavlja *ljudski kapital*, tj. *visokoobrazovanu radnu snagu* pokazala statistički neznačajnom. *Model 2* se može definirati:

$$\Delta GDP_{it} = \gamma \cdot L.LGDP_{i,t-1} + \beta_1 \cdot LEXPTER_{it} + \beta_2 \cdot LLFTER_{it} + \varepsilon_{it}; \quad i = 1,...,11; t = 1,...,22; \quad (28)$$

U nastavku se promatra *model 3* te se može zaključiti kako je parametar *L.LGDP* statistički značajan na razini pouzdanosti od 95%, a parametar *LENRTER* na razini pouzdanosti od 90%. Parametar *LEXPTERS*, tj. *državna izdvajanja po studentu* je statistički neznačajan te predstavlja *fizički kapital*. Model možemo definirati:

$$\Delta GDP_{it} = \gamma \cdot L.LGDP_{i,t-1} + \beta_1 \cdot LEXPTERS_{it} + \beta_2 \cdot LENRTER_{it} + \varepsilon_{it}; \quad i = 1,...,11; t = 1,...,22; \quad (29)$$

Kroz ove tri specifikacije modela definiran je prvi dio istraživanja odnosno ispitivale su se *istraživačke hipoteze 1* i *2* kojima se tvrdi da broj visokoobrazovanih utječe na ekonomski rast odnosno da ulaganje u visoko obrazovanje ima utjecaj na ekonomski rast. Na temelju definiranih modela može se zaključiti kako je varijabla *LENRTER* koja predstavlja broj visokoobrazovanih statistički značajna pri razini pouzdanosti od 90% te ima pozitivan utjecaj na gospodarski rast. Nadalje varijabla *LEXPTER* predstavlja ulaganje u visoko obrazovanje te je statistički značajna pri razini pouzdanosti od 99% sa pozitivnim utjecajem na gospodarski rast. Sukladno prethodnim zaključcima može se potvrditi teorijska pretpostavka Holmesa (2013) prema kojoj visoko obrazovanje, odnosno ulaganje te broj visokoobrazovanih utječe na gospodarski rast, što je u suprotnosti s rezultatima Holmesa koji je istraživanje proveo na drugom razdoblju i različitoj skupini zemalja.

Dodatna dva procijenjena modela (*model 4* i *model 5*) u *tablici 5* odnose se na kombinaciju varijabli *fizičkog* i *ljudskog kapitala* pri kojoj se za varijablu *ljudskog kapitala* koristi varijabla iz visokog obrazovanja *LENRTER* dok se za varijable *fizičkog kapitala* koriste *LFDI* odnosno *LRD* koje se ne odnose direktno na visoko obrazovanje. Pregled procijenjenih parametara upućuje na to da su varijabla *L.LGDP* te *LENRTER* statistički značajne pri razini signifikantnosti od 99% u oba modela dok je u *modelu 5* varijabla *LFDI* također značajna pri razini signifikantnosti od 99%, a u *modelu 5* varijabla *LRD* je statistički neznačajna.

Drugim se dijelom specificira prošireni ekonomski model. U osnovni ekonomski model dodaju se nezavisne varijable *fizičkog* i *ljudskog kapitala* koje nisu vezane uz visoko obrazovanje. Procijenjeni parametri i njihove statističke značajnosti te rezultati dijagnostičkih testovi modela su prikazani također u *tablici 5* (*model 6 i 7*).

U izvedenim procijenjenim modelima dobivaju se slični rezultati kao i u prethodnim modelima. Iz *model 6* može se zaključiti kako varijable *državnih izdvajanja po studentu*, tj. varijabla *LEXPTERS* te varijabla *populacije* (*POP*) gube statističku značajnost, ali ipak varijabla *L.LGDP* te varijabla koja je definira *bruto omjer upisanih u visoko obrazovanje*, *LENRTER* su značajne pri razini od 99% odnosno 90%. Model se može prikazati kao:

$$\Delta GDP_{it} = \gamma \cdot L.LGDP_{i,t-1} + \beta_1 \cdot LEXPTERS_{it} + \beta_2 \cdot LENRTER_{it} + \beta_3 \cdot LPOP + \varepsilon_{it}; \qquad i = 1,...,11; t = 1,...,22; \tag{30}$$

U procijenjenom *modelu 7* varijabla *populacije* (*POP*) se ne pokazuje statistički značajnom, ali su ipak varijabla *L.LGDP* te varijabla *državnih izdvajanja za visoko obrazovanje*, *LEXPTER* statistički značajne pri razini pouzdanosti od 99%, dok je varijabla *bruto omjera upisanih u visoko obrazovanje*, *LENRTER* statistički značajna pri 95%

$$\Delta GDP_{it} = \gamma \cdot L.LGDP_{i,t-1} + \beta_1 \cdot LEXPTER_{it} + \beta_2 \cdot LENRTER_{it} + \beta_3 \cdot LPOP + \varepsilon_{it}; \qquad i = 1,...,11; t = 1,...,22; \tag{31}$$

Na temelju prethodnih rezultata može se zaključiti kako su varijable vezane uz visoko obrazovanje, odnosno varijabla *državnih izdvajanja za visoko obrazovanje* (*LEXPTER*) te varijabla *bruto omjera upisanih u visoko obrazovanje* (*LENRTER*) statistički značajne u svim procijenjenim modelima dok varijable *državnih izdvajanja po studentu* (*LEXPTERS*) te varijable *visokoobrazovane radne snage* (*LLFTER*) ne pokazuju statističku značajnost u modelima u kojima su procijenjene. U nastavku je procijenjen model preuzet iz istraživanja Keller (2006) kojim se ispituje II. istraživačka hipoteza.

Tablica 6: Rezultati panel analize za model preuzet iz Keller (2006) (GDP)

Varijabla	*Keller (2006)*
L.LGDP	-0,153*** (0,0160)
LEXPTER	0,161*** (0,0514)
LCPI	0,0225*** (0,00797)
LGOVEXP	-0,283*** (0,0740)
LOPE	0,175*** (0,0463)
LGINI	0,151* (0,0832)
Konstanta	2,639*** (0,447)
F-test	0,0000
LM test	1,000
Hausman test	/
Odabrani model	**Fiksni efekt**
Broj opažanja	108
R2	0,638

, **, * označava statističku značajnost na razini 10%, 5% i 1%; vrijednosti u zagradama su t-vrijednosti*
Izvor: izrada autora

Na temelju dobivenih rezultata panel analize modela prema Keller može se zaključiti kako su varijable *državnih izdvajanja za visoko obrazovanje* (*LEXPTER*), *državnih izdvajanja za obrazovanje* (*LGOVEXP*), *otvorenost ekonomije* (*LOPE*) te *inflacija* (*CPI*) statistički značajne pri razini signifikantnosti od 99% dok je varijabla *LGINI* statistički značajna pri razini signifikantnosti od 90%. Nadalje, iz prezentiranih rezultata može se zaključiti kako ulaganje u visoko obrazovanje, varijabla *LEXPTER*, ima pozitivan utjecaj na rast *GDP-a* što opovrgava rezultate Keller (2006) koja nije uspjela dokazati pozitivnu vezu. Naprotiv, prema rezultatima Keller (2006), varijabla ulaganja u visoko obrazovanje ima negativan utjecaj te je statistički značajna.

U nastavku rada koristit će se prethodno definirani predložak preko kojeg će se formirati modeli, s naznakom kako će se sada kao nezavisna varijabla koristiti diferencirana vrijednost varijable *GDPPC* te će se dobiveni rezultati međusobno uspoređivati. Uzevši u obzir prethodno procijenjene korelacijske matrice između parova nezavisnih varijabli formira se 7 modela. Početnih 5 modela definira modificirani Solowljev model koji uključuje ljudski kapital, koji uključuje lagiranu vrijednost *LGDPPC-a* te po jednu varijablu *fizičkog* i *ljudskog kapitala*. *Model 6* i *model 7* su prošireni Solowljevi modeli dok će se naknadno prikazati

model preuzet iz istraživanja Keller (2006). U *tablici 7* prikazane su procijene za modificirani Solowljev te prošireni Solowljev model.

Tablica 7: Rezultati panel analize (GDPPC)

Varijabla	*Model 1a*	*Model 2a*	*Model 3a*	*Model 4a*	*Model 5a*	*Model 6a*	*Model 7a*
L.LGDPPC	-0,105*** (0,0201)	-0,0838*** (0,0188)	-0,0803*** (0,0192)	-0,0404*** (0,0134)	-0,0562*** (0,0196)	-0,126*** (0,0236)	-0.099*** (0.0220)
Varijable fizičkog i ljudskog kapitala vezane uz visoko obrazovanje							
LEXPTER	0,180** (0,0745)	0,155** (0,0765)				0,188** (0,0746)	
LENRTER	0,0931** (0,0390)		0,0911* (0,0517)	0,0511** (0,0242)	0,0926*** (0,0298)	0,130*** (0,0433)	0.121** (0.0530)
LEXPTERS			-0,00481 (0,0565)				-0.00946 (0.0571)
LLFTER		0,0367 (0,0318)					
Ostale varijable fizičkog i ljudskog kapitala							
LPOP						0,0319 (0,0202)	0.0314* (0.0186)
LFDI				0,0316*** (0,00835)			
LRD					-0,00824 (0,0259)		
Konstanta	0,138 (0,221)	0,277 (0,225)	0,469 (0,292)	0,207** (0,0939)	0,214 (0,146)	0,163 (0,232)	0.542* (0.305)
F-test	0,0567	0,0000	0,7999	0,0989	0,1433	0,1194	0.1131
LM test	1,0000	0,0304	1,0000	1,0000	1,0000	1,0000	1.0000
Hausman test	/	0,0000	/	/	/	/	/
Odabrani model	**Združeni**	**Fiksni efekt**	**Združeni**	**Združeni**	**Združeni**	**Združeni**	**Združeni**
Broj opažanja	133	133	139	201	190	129	135
R2	0,178	0,135	0,133	0,123	0,088	0,2	0.152

, **, * označava statističku značajnost na razini 10%, 5% i 1%; vrijednosti u zagradama su t-vrijednosti*
Izvor: izrada autora

Na temelju procjene prvog modela (*model 1a*) može se zaključiti kako je varijabla *L.LGDPPC* statistički značajna pri razini pouzdanosti od 99% dok su varijabla *LEXPTER* te varijabla *LENRTER* statistički značajne pri razini pouzdanosti od 95%. Procijenjeni model prikazan je u nastavku:

$$\Delta GDPPC_{it} = \gamma \cdot L.LGDPPC_{i,t-1} + \beta_1 \cdot LEXPTER_{it} + \beta_2 \cdot LENRTER_{it} + \varepsilon_{it}; \qquad i = 1,...,11; t = 1,...,22; \tag{32}$$

Iduća specifikacija modela (*model 2a*) procjenjuje kako je varijabla *L.LGDPPC* statistički značajna pri razini pouzdanosti od 99%, varijabla *LEXPTER*, tj. varijabla *državnih izdvajanja*

za visoko obrazovanje statistički značajna pri razini signifikantnosti od 95% dok se varijabla *visokoobrazovane radne snage* odnosno *LLFTER* nije pokazala statistički značajnom. Model je prikazan u nastavku:

$$\Delta GDPPC_{it} = \gamma \cdot L.LGDPPC_{i,t-1} + \beta_1 \cdot LEXPTER_{it} + \beta_2 \cdot LLFTER_{it} + \varepsilon_{it}; \quad i = 1,...,11; t = 1,...,22; \tag{33}$$

Model 3a procjenjuje varijablu *L.LGDPPC* statistički značajnom pri razini signifikantnosti od 99%, varijablu *bruto omjera upisanih u visoko obrazovanje, LENRTER* statistički značajnom pri razini od 90%, dok varijabla *državnih izdvajanja po studentu, LEXPTERS* ne pokazuje statističku značajnost.

$$\Delta GDPPC_{it} = \gamma \cdot L.LGDPPC_{i,t-1} + \beta_1 \cdot LENRTER_{it} + \beta_2 \cdot LEXPTERS_{it} + \varepsilon_{it}; \quad i = 1,...,11; t = 1,...,22; \tag{34}$$

Kroz ova tri modela testirale su se prve dvije hipoteze kojima se tvrdi da broj visokoobrazovanih utječe na ekonomski rast odnosno da ulaganje u visoko obrazovanje ima utjecaj na ekonomski rast. Sukladno tome može se zaključiti kako je varijabla *L.LGDPPC* statistički značajna pri razini signifikantnosti 99% u sva tri modela. Prvim modelom može se također zaključiti kako su *ulaganje u visoko obrazovanje* te *bruto omjer upisanih u visoko obrazovanje* statistički značajni pri razini signifikantnosti 95%. U drugom modelu varijabla *državnih izdvajanja za visoko obrazovanje* je statistički značajna pri razini signifikantnosti od 95% dok je varijabla *visokoobrazovane radne snage* (*LLFTER*) statistički neznačajna. Procijenjeni *model 3a* pokazuje kako je varijabla *bruto omjer upisanih u visoko obrazovanje* statistički značajna pri razini signifikantnosti od 90% dok se varijabla državnih izdvajanja po studentu ne pokazuje statistički značajnom.

Modeli 4a i *5a* su također formirani prema modificiranom Solowljevom modelu s iznimkom što varijable *fizičkog kapitala* nisu vezane uz visoko obrazovanje. *Model 4a* procjenjuje *L.LGDPPC* statistički značajnom pri razini signifikantnosti od 99%, varijablu *LENRTER* značajnom pri razini od 95% te varijablu *LFDI* statistički značajnom pri razini signifikantnosti od 99%. U *modelu 5a* varijable *LGDPPC* te *LENRTER* statistički su značajne pri 99% dok je varijabla *LRD* statistički neznačajna.

Na temelju procjena specifikacija *modela 6a* i *7a* koje definiraju prošireni Solowljev model može se zaključiti kako je zavisna varijabla *LGDPPC* statistički značajna pri razini signifikantnosti od 99%. U *modelu 6a* varijabla *državnih izdvajanja za visoko obrazovanje* (*LEXPTER*) statistički je značajna pri razini signifikantnosti od 95%, a varijabla b*ruto omjera*

upisanih u visoko obrazovanje pri razini signifikantnosti od 99%. Varijabla *populacije* (*POP*) pokazala se statistički neznačajnom. Kod *modela 7a* varijabla b*ruto omjera upisanih u visoko obrazovanje* statistički je značajna pri razini signifikantnosti od 95% dok je varijabla *populacije* (*POP*) za razliku od prethodnog modela statistički značajna pri razini signifikantnosti od 90%. Varijabla *državnih izdvajanja po studentu* (*LEXPTERS*) se nije pokazala statistički značajnom.

Iz rezultata za proširenu Solowljev model može se zaključiti kako varijabla *LENRTER*, tj. *bruto omjer upisanih u visoko obrazovanje* utječe na gospodarski rast u oba procijenjena modela, varijabla LEXPTER također utječe na gospodarski rast dok *populacija* (*POP*) utječe na gospodarski rast samo u *modelu 7a*

Tablica 8: Rezultati panel analize za model preuzet iz Keller (2006) (GDPPC)

Varijabla	*Keller (2006)(1)*
L.LGDPPC	-0.156*** (0.0272)
LEXPTER	0.237** (0.111)
LCPI	0.0188 (0.0170)
LGOVEXP	-0.271* (0.161)
LOPE	0.327*** (0.104)
LGINI	0.485*** (0.181)
Konstanta	-1.997** (0.764
F-test	0,0120
LM test	1,000
Hausman test	/
Odabrani model	**Fiksni efekt**
Broj opažanja	119
R2	0,260

, **, * označava statističku značajnost na razini 10%, 5% i 1%; vrijednosti u zagradama su t-vrijednosti*
Izvor: izrada autora

Na osnovi rezultata procijenjenog modela prema Keller (2006) razvidno je kako su varijable *LGDPPC*, *LOPE*, te *LGINI* statistički značajne pri razini signifikantnosti od 99%, varijabla *LEXPTER* pri razini od 95%, *LGOVEXP* pri razini od 90% te se jedino varijabla inflacije pokazala statistički neznačajnom. Sukladno rezultatima može se zaključiti kako se varijabla iz visokog obrazovanja, *LEXPTER*, ponovno pokazala statistički značajnom kao i u prethodnom

modelu gdje se kao nezavisna varijabla koristio *GDP*. Ovaj procijenjeni model također opovrgava rezultate Keller (2006) koja nije pronašla statističku značajnost između ulaganja u visoko obrazovanje i gospodarskog rasta. Proizašli smjerovi utjecaja potvrđuju teorijska očekivanja, a procijenjeni koeficijenti su veoma slični u svim specifikacijama modela s naznakom kako se model *Keller* u kojem se *GDP* promatrao kao zavisna varijabla pokazao statistički značajnim od modela *Keller (1)* sa *GDPPC* kao zavisnom varijablom.

Kako bi se ispitala treća ujedno i posljednja istraživačka hipoteza, kao zavisna varijabla korištena je *bruto omjer upisanih u visoko obrazovanje*, tj. varijabla *ENRTER*. Trećom istraživačkom hipotezom pokušat će se dokazati i objasniti utjecaji prema kojima ulaganje u visoko obrazovanje ima pozitivan utjecaj na broj visokoobrazovanih putem izdataka po tercijarnom stupnju obrazovanja te po studentu u istom.

Tablica 9: Korelacijska matrica između parova nezavisnih varijabli dok se *ENRTER* promatra kao zavisna varijabla

	ENRTER	dGDP	EXPTER	PRIMSEC	FER
ENRTER	1				
dGDP	-0,3238	1			
EXPTER	0,1634	-0,0737	1		
PRIMSEC	0,1525	0,0017	**-0,5511***	1	
FER	0,0610	-0,1808	0,2778	-0,2409	1

* se označava statistička značajnost na razini od 5%; istaknute vrijednosti upućuju na korelaciju iznad 0,5
Izvor: izrada autora

Unutar posljednje korelacijske matrice uočava se srednje jaka korelacija od -0,5511 između *državnih izdvajanja za obrazovanje* i varijable *državna izdvajanja za primarno + sekundarno obrazovanje kao % cjelokupnog državnog izdvajanja za obrazovanje*. Kao i u prethodnim slučajevima važno je obratiti pažnju pri sastavljanju ekonometrijskih modela kako se ne bi pojavio problem multikolinearnosti.

Tablica 10: Rezultati panel analize za model (*ENRTER*)

Varijabla	*Model 1*
dGDP	-12.53 (9.982)
EXPTER	0.930** (0.447)
PRIMSEC	0.650** (0.297)
FER	50.47*** (6.802)
Konstanta	-69.84*** (26.04)
F - test	0.0000
LM test	0.0000
Hausman test	0.8827
Odabrani model	Slučajni efekt
Broj opažanja	111

, **, * označava statističku značajnost na razini 10%, 5% i 1%; vrijednosti u zagradama su t-vrijednosti*
Izvor: izrada autora

U izvedenom procijenjenom modelu varijabla *dGDP*, odnosno *porast bruto domaćeg proizvoda* je jedina koja se nije pokazala statistički značajnom, dok su *državna izdvajanja za visoko obrazovanje* (*EXPTER*) te *izdvajanja za primarno i sekundarno obrazovanje* (*PRIMSEC*) statistički značajne pri razini signifikantnosti od 95%, a *fertilitet* (*FER*) pri razini signifikantnosti od 99%. Nadalje, smjerovi utjecaja uključenih varijabli su pozitivi što je u skladu s teorijskim uporištima i pretpostavkama, uz napomenu kako je smjer utjecaja varijable *dGDP* negativan, ali varijabla nije statistički značajna. Konačno, može se zaključiti da procijenjeni model pruža dobra svojstva budući su nezavisne varijable statistički značajne te pozitivnog predznaka

U konačnici, nakon osvrta na sve procijenjene modele te izvedene dijagnostičke testove može se zaključiti kako svi modeli sadržavaju dobra svojstva, odnosno svaka pojedina specifikacija modela je dobro definirana. Stoga, dobiveni rezultati panel analize omogućavaju nastavak analize te interpretacije dobivenih rezultata u ekonomskom smislu, a koji će biti temelj za donošenje konačnog zaključka o postavljenim istraživačkim hipotezama

5.5 Analiza rezultata

S obzirom na kompleksnost modela utjecaja visokog obrazovanja na gospodarski rast nije bilo moguće korištenje te formiranje samo jednog ekonometrijskog modela. Ukoliko bi se sve nezavisne varijable istovremeno uvrstile u model, model bi sadržavao prevelik broj nezavisnih varijabli što bi dovelo do problema multikolinearnosti i endogenosti. Kako bi se izbjegli navedeni problemi u samom početku empirijske analize definiran je osnovni model prema modificiranom Solowljevom modelu koji uključuje ljudski kapital. Navedeni model sadržavao je kombinacije jedne varijable *fizičkog* te jedne varijable *ljudskog kapitala*. Dakle, polazi se od pretpostavke da svaka kombinacija dviju varijabli pozitivno utječe na gospodarski rast. U radu su na temelju dijagnostičkih testova dani rezultati za onaj model koji se na temelju istih pokazao najprikladnijim (združeni, s fiksnim efektom ili sa slučajnom efektom). Inicijalno se interpretira utjecaj razmatranih kontrolnih varijabli u određivanju utjecaja visokog obrazovanja na gospodarski rast u zemljama srednje i istočne Europe. Preciznije u modelima u kojima je *fizički kapital* promatran kroz varijable ulaganja u visoko obrazovanje, zaključuje se kako je varijabla *LEXPTER*, odnosno *državna izdvajanja za visoko obrazovanje* statistički značajna u svim modelima u *tablici 5* te u modelu prema *Keller* u *tablici 6* , u situaciji kada se *GDP* promatra kao zavisna varijabla, te je također statistički značajna i kada se gospodarski rast definira GDPPC-om (*tablica 7* i *8*) što dokazuje prethodne empirijske pretpostavke o utjecaju varijabli *fizičkog kapitala* na *gospodarski rast* (Barro i Sala-i-Martin, 1995, 2004; De la Fuente i Doménech 2006, Cohen i Soto 2007). Važno je napomenuti kako se varijabla *državnih izdvajanja u visoko obrazovanje* (*LEXPTER*) pokazala statistički značajnijom nego varijabla *državnih izdvajanja po studentu u viskom obrazovanju* (*LEXPTERS*). Shodno navedenom, empirijsko objašnjenje se očituje u tome da će rast *državnih izdvajanja za visoko obrazovanje* potaknuti povećanje *gospodarskog rasta* u zemljama srednje i istočne Europe. Nadalje, u modelima u kojima je ljudski kapital promatran kroz varijable ulaganja u visoko obrazovanje, varijabla *bruto omjera upisanih u visoko obrazovanje* (*LENRTER*) pokazuje se statistički značajnom u svim modelima sa *GDP-om* te *GDPPC-om* kao zavisnom varijablom. Zaključuje se kako je moguće potvrditi prethodna empirijska tumačenja o manjem doprinosu ljudskog kapitala u objašnjenju gospodarskog rasta (Appleton, Atherton i Bleaney 2013; Benhabib i Spiegel 1994). U specifikacijama proširenih Solowljevih modela (*modeli 6* i *7*, u *tablicama 5* i *7*) varijable ljudskog kapitala, odnosno *bruto omjer upisanih u visoko obrazovanje* (*LENRTER*) pokazala

se statistički značajnom dok se varijabla *godišnjeg porasta stanovništva* (*POP*) pokazala statistički značajnom s negativnim smjerom utjecaja samo u *tablici 7* u *modelu 7a*, što se može protumačiti kontinuiranim padom rasta stanovništva u zemljama srednje i istočne Europe. Nadalje ovakvim rezultatima potvrđuju se ranija empirijska tumačenja o populaciji kao „kočnici" gospodarskom rastu (Kelly, Schmidt 1995). Iz modela preuzetog iz istraživanja prema *Keller* (*tablica 6* i *8*) može se zaključiti kako *državna izdvajanja u visokog obrazovanje* imaju statistički značajan i pozitivan smjer utjecaja na gospodarski rast. Ovaj zaključak nije u skladu s nalazom Keller (2006) koja nije pronašla statistički značajnu i pozitivnu vezu između ulaganja u visoko obrazovanje te gospodarskog rasta. . U konačnici potvrđuju se i rezultati istraživanja Sambt, Redek, Majcen i Čok (2010) koji su došli do zaključka kako bi povećanje javnih izdataka za visoko obrazovanje rezultiralo povećanjem BDP-a u Sloveniji.

Nedostatak istraživanja utjecaja visokog obrazovanja, ulaganja u visoko obrazovanja na ekonomski rast te rezultati istraživanja Sambt, Redek, Majcen i Čok (2010) su glavni faktori koji su potaknuli na provođenje ovog istraživanja kojim se pokušao dobiti odgovor utječe li ulaganje u visoko obrazovanje na ekonomski rast, utječe li broj visoko obrazovanih na ekonomski rast i ima li ulaganje u visoko obrazovanje pozitivan utjecaj na broj visokoobrazovane populacije.

U ovom dijelu istraživanja ispituje se postavljena **istraživačka hipoteza 1** koja pretpostavlja kako *broj visokoobrazovanih utječe na gospodarski rast u zemljama srednje i istočne Europe*. Cilj ove hipoteze je empirijski pružiti dokaze o razmatranoj vezi na relevantnim pokazateljima istih. Prema rezultatima panel analize prikazanima u *tablici 5* i *tablici 7* broj visokoobrazovanih (*LENRTER*) je statistički značajna varijabla u svim modelima. Sukladno tome mogu se prihvatiti teorijske pretpostavke Holmesa (2013) koji navodi kako bi trebao postojati pozitivan utjecaj broja visokoobrazovanih na gospodarski rast, ali isto ne uspijeva dokazati. Nadalje u prilog tome idu i empirijski dokazi Baldacci et al (2008), koji zaključuje kako povećani omjer upisanih u obrazovni sustav ima pozitivan utjecaj na ekonomski rast razvijenih zemalja. Uzevši u obzir sve prethodno navedene tvrdnje, istraživačka hipoteza I može se prihvatiti te se zaključuje kako *broj visokoobrazovanih ima pozitivan i statistički značajan utjecaj na gospodarski rast u zemljama srednje i istočne Europe*.

Slijedi razmatranje rezultata panel analize modela s ciljem ispitivanja **istraživačke hipoteze 2** kojom se pretpostavlja kako *ulaganje u visoko obrazovanje ima utjecaj na gospodarski rast u zemljama srednje i istočne Europe*. Kao što je prethodno navedeno, literatura u svom

teorijskom te empirijskom dijelu ne pruža dovoljna uporišta te dokaze kojima bi se *a priori* odredila signifikantnost i smjer utjecaja *ulaganja u visoko obrazovanje na gospodarski rast*. Slijedom toga na temelju varijabli *državnih izdvajanja u visoko obrazovanje* te *izdvajanja po studentima u visokom obrazovanju od strane države* može se zaključiti kako varijabla *izdvajanja za visoko obrazovanje* (*LEXPTER*) je statistički značajna u svim modelima u kojima je korištena te se može potvrditi pretpostavka istraživačke hipoteze kako ima statistički značajan i pozitivan utjecaj na gospodarski rast. S druge strane varijabla *izdvajanja po studentu u visokom obrazovanju od strane države* (*LEXPTERS*) nije značajna ni u jednom od korištenih modela. Može se zaključiti kako *državna izdvajanja za visoko obrazovanje* imaju pozitivan utjecaj na gospodarski rast te se potvrđuje istraživačka hipoteza 2.

Nastavno na prethodno, slijedi razmatranje **istraživačke hipoteze 3** kojom se pretpostavlja kako *ulaganje u visoko obrazovanje ima pozitivan utjecaj na broj visokoobrazovane populacije u zemljama srednje i istočne Europe*. Nakon izvedenih rezultata u *tablici 10* koji impliciraju da su gotovo sve promatrane varijable, uz iznimku *rasta GDP-a* (*dGDP*), značajne te pozitivne u objašnjavanju utjecaja ulaganja u visoko obrazovanje na broj visokoobrazovane populacije u zemljama srednje i istočne Europe proizlazi potvrda postavljene *istraživačke hipoteze 3*. Konkretnije, rezultati istraživanja naglašavaju važnost kvalitete ulaganja u visoko obrazovanje što rezultira većim brojem visokoobrazovanih koji prema *istraživačkoj hipotezi 1* imaju pozitivan i statistički značajan utjecaj na gospodarski rast u zemljama srednje i istočne Europe.

6. ZAKLJUČAK

Obrazovni sustavi u zemljama srednje i istočne Europe bili su predmetom brojnih istraživanja i polemika u posljednja dva desetljeća. Zemlje srednje i istočne Europe formirale su se iz zemalja koje su desetljećima bile pod autoritativnom kontrolom komunizma te državnog sustava. Obrazovni sustavi u ovim državama bili su usklađeni s centraliziranom birokracijom ekonomskog planiranja koja je potražnju za obrazovanjem određivala na temelju predviđanja te učinaka uslužnih djelatnosti. Značajno gospodarsko i kulturno zaostajanje zemalja srednje i istočne Europe izazvalo je nezadovoljstvo među populacijom navedenih zemalja, te su diljem Europe pokrenute revolucije protiv režima. Nakon raspada režima, novoformirane zemlje stekle su okvirnu političku podlogu za početak gospodarske tranzicije. Sukladno tomu okreću se tržišnoj privredi te demokratskom društvu. Utjecaj visokog obrazovanja kao tema bila je i

još uvijek je predmetom mnogih istraživanja i radova. Rezultati istraživanja su vrlo kontradiktorni, tako su neki otkrili značajne pozitivne odnose, dok su drugi pronašli negativne odnosno nikakve utjecaje. Dok je određeni segment literature dokazao pozitivnu ulogu obrazovanja u zemljama srednje i istočne Europe, tek je nekolicina istraživanja promatrala utjecaje visokog obrazovanja na gospodarski rad u navedenim zemljama ali korištenjem neadekvatnih pokazatelja i metoda. Sukladno tome ni rezultati nisu pokazali nikakve značajnije utjecaje. Stoga, primarni cilj ovoga istraživanja je dokazati ulogu visokog obrazovanja, ulaganja u visoko obrazovanje te broja visokoobrazovanih na gospodarski rast u zemljama srednje i istočne Europe.

Rezultati empirijskog istraživanja gotovo u cijelosti opravdavaju očekivanja zasnovana na teorijskim pretpostavkama. Polazeći od kontrolnih varijabli uvrštenih u model gospodarskog rasta promatranog putem *GDP-a* te *GDPPC-a*, između varijabli fizičkog i ljudskog kapitala pokazuje se kako *državna izdvajanja za visoko obrazovanje* potiču gospodarski rast, isto vrijedi i za *bruto omjer upisanih u visoko obrazovanje*. Nadalje, od varijabli fizičkog i ljudskog kapitala koje se ne odnose na obrazovanje, pokazuje se kako *direktne strane investicije* potiču gospodarski rast dok se isto ne može reći za *državna izdvajana u istraživanje i razvoj*. Iz modela preuzetog iz istraživanja Keller (2006) pokazuje se kako, uz *državna izdvajanja za visoko obrazovanje*, *otvorenost ekonomije*, *GINI koeficijent* te *inflacija* potiču gospodarski rast promatran *GDP-om* dok kod *GDPPC-a* varijabla *inflacije* gubi značajnost.

Drugi pravac istraživanja usmjeren je na ispitivanje ulaganja u visoko obrazovanje kod povećanja broja visokoobrazovanje populacije, zbog čega je i formirana *istraživačka hipoteza 3*. Stoga, formiraju se četiri modela sa varijablama *državna izdvajanja po studentu, stopa fertiliteta, državna izdvajanja za primarno i sekundarno obrazovanje* te *nezaposlenost*. Rezultati ekonometrijske analize pokazuju da gotovo svi elementi, isključujući *nezaposlenost*, značajno utječu na broj visokoobrazovane populacije pri čemu se potvrđuje postavljena hipoteza.

U ovom istraživanju panel analizom procijenili su se utjecaji ulaganja u visoko obrazovanje na gospodarski rast i na broj visokoobrazovanih te utjecaji broja visokoobrazovanih na gospodarski rast. Rezultati istraživanja ukazuju na povezanost visokog obrazovanja i gospodarskog rasta u zemljama srednje i istočne Europe te se zaključuje kako ulaganja u

visoko obrazovanje kao i broj visokoobrazovanih imaju pozitivan i značajan utjecaj na gospodarski rast. Zbog toga bi trebalo potaknuti interes te snažniji porast izdvajanja u obrazovanje. Na taj bi se način povezalo obrazovanje s potrebama gospodarstva čime bi se pozitivno stimulirao gospodarski rast u zemljama srednje i istočne Europe. Rezultati ovog istraživanja otvaraju prostor za daljnja istraživanja. Osim dva promatrana aspekta visokog obrazovanja (ulaganje u visoko obrazovanje, broj visokoobrazovanih) bili bi zanimljivo istražiti utjecaj kvalitete visokog obrazovanja na gospodarski rast u promatranim zemljama.

SAŽETAK

Ključne riječi: visoko obrazovanje, gospodarski rast, panel analiza

Vezano uz trendove u obrazovanju u zemljama srednje i istočne Europe koje su bile pod upravom komunističkog režima, cilj je ovoga rada izvršiti analizu utjecaja visokog obrazovanja te broja visokoobrazovanih na gospodarski rast u zemljama srednje i istočne Europe. Nakon teorijskog prikaza relevantnih istraživanja vezanih uz obrazovanje, rad se nastavlja formiranjem ekonometrijskih modela te procjenom istih primjenom panel analize. Pretpostavka je bila da će državna izdvajanja za visoko obrazovanje te broj visokoobrazovanih imati pozitivan utjecaj na gospodarski rast. Rezultati analize, unutar uzorka od 11 zemalja srednje i istočne Europe u razdoblju od 1993. do 2014. godine, dokazuju prethodno navedenu pretpostavku kako državna izdvajanja za visoko obrazovanje te broj visoko obrazovanih utječu na gospodarski rast.

SUMMARY

Key words: tertiary education, economic growth, panel data analysis

Regarding the educational trends in Central and Eastern European countries which were under the direction of communist regime, the aim of this research is to analyze the impact of tertiary education and gross enrollment ratio in tertiary education on economic growth in Central and Eastern European countries. After theoretical background of relevant educational literature, this research continues by forming econometric models and econometric analysis using panel data analysis. The assumption was that government expenditure per tertiary education will have positive impact on economic growth as well as gross enrollment ratio in tertiary education. The results, for the sample of 11 Central and Eastern European countries over the time span 1993-2014, show that the government expenditure per tertiary education has positive impact on economic growth as well as gross enrollment ratio in tertiary education.

LITERATURA

Knjige

1. Berryman, S.E. (2000): Hidden Challenges to Education Systems in Transition Economies. 1. izdanje Washington: The World Bank.
2. Cazes, S., & Nešporová, A. (2003). Labour markets in transition: balancing flexibility & security in Central and Eastern Europe. International Labour Organization.
3. Krueger, D. (2009): Makroekonomika, Katedra za ekonomiju Sveučilište u Pennsylvaniji.
4. Pritchard, R.O.M., Klumpp, M., Teichler, U. (2015): Diversity and Excellence in Higher Education: Can the Challenges be Reconciled?, Sense.
5. Psacharopoulos, G., Schultz, T. W. (1984). The contribution of education to economic growth: International comparisons. Washington, DC: World Bank.
6. Tremblay, K., Basri, E., Arnal, E. (2008). Tertiary education for the knowledge society (Vol. 1). Paris: OECD.
7. Zajda, J., Biraimah, K., Gaudelli, W. (2008): Education and Social Inequality in the Global Culture, 1. izdanje Springer.

Časopisi, radne verzije članaka i stručni radovi:

1. Aghion, P. et al. (2009): The causal impact of education on economic growth: evidence from US, Neobjavljeni rad
2. Altinok, N., Murseli, H. (2007). International database on human capital quality. Economics Letters, 96(2), 237-244.
3. Appleton, S., Atherton, P., Bleaney, M. (2013): International School Test Scores and Economic Growth, Bulletin of Economic Research, 65 (1), str. 82-90.
4. Baldacci, E., Clements, B., Gupta, S., Cui, Q. (2008): Social Spending, Human Capital, and Growth in Developing Countries, World Development, 36 (8), str. 1317-1341.
5. Barro, R. J. (1991): Economic Growth in a Cross Section of Countries, The Quarterly Journal of Economics, 106 (2), str. 407-443.

6. Barro, R. J. (1996): Determinants of economic growth: A cross-country empirical study, NBER Working Paper 5698, National bureau of economic research, Cambridge.
7. Barro, R. J. (2000): Inequality and Growth in a Panel of Countries, Journal of Economic Growth , 5 (1), str. 5-32.
8. Barro, R. J., Lee, J.-W. (1993): International Comparisons of Educational Attainment, Journal of monetary economics, 32 (3), str. 363-394.
9. Barro, R. J., Sala-i-Martin, X. (2004): Economic Growth (2nd izd.), London: The MIT Press.
10. Benhabib, J., Spiegel, M. M. (1994): The role of human capital in economic development evidence from aggregate cross-country dana, Journal of Monetary Economics, 34 (2), str. 143-173.
11. Berryman, S. E. (2000): Hidden Challenges to Education Systems in Transition Economies (1st izd.), Washington: The World Bank.
12. Bhattacharyya, S., Jha, R. (2013): Economic Growth, Law and Corruption: Evidence from India, Comparative Economic Studies, 55 (2), str. 287-313.
13. Birzea, C. (1996): Educational Reform and Power Struggles in Romania, European Journal of Education, 31 (1), str. 97-107.
14. Blöndal, S., Field, S., Girouard, N. (2002). Investment in human capital through upper-secondary and tertiary education. OECD Economic Studies, 2002(1), 41-89.
15. Boarini, R., Martins, J. O., Strauss, H., De la Maisonneuve, C., Nicoletti, G. (2008). Investment in tertiary education: Main determinants and implications for policy. CESifo Economic Studies, 54(2), 277-312.
16. Bond, S. R., Hoeffler, A., Temple, J. R. (2001): GMM estimation of empirical growth models.
17. Bond, S., 2002. Dinamic Panel Data Models: A guide to Micro Data Methods and Practice. Cemmap working paper 09/02. The Institut for Fiscal Studies Department of Economic, UCL. Dostupno na: http://www.cemmap.ac.uk/wps/cwp0209.pdf [pristupljeno 03.06.2015.].
18. Carstensen, K., Toubal, F. (2004). Foreign direct investment in Central and Eastern European countries: a dynamic panel analysis. Journal of comparative economics, 32(1), 3-22.

19. Caselli, F., Esquivel, G., Lefort, F. (1996): Reopening the Convergence Debate: A New Look at Cross-Country Growth Empirics, Journal of Economic Growth, 1, str. 363-389.
20. Castelló-Climent, A., Hidalgo-Cabrillana, A. (2012): The role of educational quality and quantity in the process of economic development, Economics of Education Review, 31 (4), str. 391-409.
21. Cerych, L. (1995): Educational Reforms in Central and Eastern Europe, European Journal of Education, str. 423-435.
22. Cerych, L. (1999): Educational Reforms in Central and Eastern Europe: Processes and Outcomes, European Education, str. 5-38.
23. Chatterji, M. (1998): Tertiary Education and Economic Growth, Regional Studies, 32 (4), str. 349-354.
24. Cincotta, R. P., & Engelman, R. (1997). Economics and rapid change: the influence of population growth.
25. Cohen, D., Soto, M. (2007): Growth and human capital: good data, good results, Journal of Economic Growth, 12, str. 51-76.
26. De la Fuente, A., Doménech, R. (2006): Human capital in growth regressions: How much difference does data quality make? Journal of the European Economic Association, 4 (1), str. 1-36.
27. Dobbins, M., Knill, C. (2009). Higher education policies in Central and Eastern Europe: convergence toward a common model?. Governance, 22(3), 397-430.
28. Gemmell, N. (1996): Evaluating the impacts of human capital stocks and accumulation on economic growth: Some new evidence. Oxford bulletin of economics and statistics, 58(1), 9-28.
29. Glaeser, E. L., La Porta, R., Lopez-de-Silanes, F., Shleifer, A. (2004): Do Institutions Cause Growth? Journal of Economic Growth, 9 (3), str. 271-303.
30. Gylfason, T. (2001): Natural resources, education, and economic development. European economic review, 45(4), 847-859.
31. Hanushek , E., Wößmann, L. (2007): The Role of Education Quality in Economic Growth, World Bank Policy Research Working Paper 4122.
32. Hanushek, E. A., Kimko, D. D. (2000): Schooling, Labor Force Quality, and the Growth of Nations. American Economic Review, 90 (5), str. 1184-1208.
33. Henderson, D. J., Papageorgiou, C., Parmeter, C. F. (2012): Growth Empirics without Parameters, The Economic Journal, 122 (559), str. 125-154.

34. Heyneman, S. P. (2006): The Effectiveness of Development Assistance in Education: An Organizational Analysis, Journal of International Cooperation in Education, 9 (1), str. 7-25.
35. Holmes, C. (2013): Has the Expansion of Higher Education Led to Greater Economic Growth? National Institute Economic Review, 224 (1).
36. Keller, K. R. (2006): Investment in primary, secondary, and higher education and the effects on economic growth, Contemporary Economic Policy, 24 (1), str. 18-34.
37. Klasen, S. (2002): Low schooling for girls, slower growth for all? Cross- country evidence on the effect of gender inequality in education on economic development. The World Bank Economic Review, 16(3), 345-373.
38. Klun, M., Šućur, M. (2014): Higher Education – Importance and Funding in Slovenia, International Public Administration Review 8, 1-2.
39. Krueger, A. B., Lindahl, M. (2001): Education for Growth, Journal of Economic Literature, 39, str. 1101-1136.
40. Kruss, G. et al. (2015): Higher education and economic development: The importance of building technological capabilities, International Journal of Educational Development, 43, str. 22-31.
41. Kwiek, M. (2004). The emergent European educational policies under scrutiny: the Bologna Process from a Central European perspective. European Educational Research Journal, 3(4), 759-776.
42. Lau, L. J., Jamison, D. T., Liu, S. C., Rivkin, S. (1993): Education and economic growth Some cross-sectional evidence from Brazil. Journal of development economics, 41(1), 45-70.
43. Levine, R., Renelt, D. (1992): A Sensitivity Analysis of Cross-Country Growth Regressions, The American Economic Review, 82 (4), str. 942-963.
44. Lucas, R. E. (1988). On the mechanics of economic development. Journal of monetary economics, 22(1), 3-42.
45. Machlup, F. (1970): Education and economic growth, 338 (9) M3, Lincoln: University of Nebraska Press.
46. Mankiw, G., Romer, D., Weil, D. N. (1992): A Contribution to the Empirics of Economic Growth, The Quarterly Journal of Economics, 107 (2), str. 407-437.
47. Meyer, J. W., Ramirez, F. O., Rubinson, R., Boli-Bennett, J. (1977). The world educational revolution, 1950-1970. Sociology of education, 242-258.

48. Nair, B., Smart, W., Smyth, R., Sector, T. (2007). How does investment in tertiary education improve outcomes for New Zealanders?. Social Policy Journal of New Zealand, 31, 195.
49. Nelson, R. R., Phelps, E. S. (1966): Investment in humans, technological diffusion, and economic growth. The American economic review, 56(1/2), 69-75.
50. Oliveira Martins, J., Boarini, R., Strauss, H., De la Maisonneuve, C., Saadi, C. (2007). The policy determinants of investment in tertiary education.
51. Pastuović, N. (1996): Upravljanje i reformiranje obrazovnih sustava: Osvrt na reforme u postkomunističkim zemljama, Društveno istraživanje Zagreb, str. 35-58.
52. Pritchett, L. (2001): Where Has All the Education Gone? World Bank Economic Review, 15 (3), str. 367-391.
53. Psacharopoulos, G., Patrinos, H. A. (2004). Returns to investment in education: a further update. Education economics, 12(2), 111-134.
54. Rado, P. (2001): Transition in education. Policy making and the key educational policy areas in the Central-European and Baltic Countries. Budapest: Open Society Institut, 1-3.
55. Riddell, William Craig. (2006): The impact of education on economic and social outcomes: An overview of recent advances in economics. Canadian Policy Research Networks.
56. Romer, P. M. (1990): Human Capital and Growth: Theory and Evidence, Carnegie-Rochester Conference Series on Public Policy, 32, str. 251-286.
57. Sadlak, J. (1991): The development of higher education in Eastern and Central Europe in the aftermath of recent changes, Prospects, 21 (3), str. 401-412.
58. Sambt, J., Redek , T., Majcen , B., Čok, M. (2010.): Increase in public expenditures on tertiary education: A burden to public finances or growth stimulus? Ljubljana, Faculty of Economics.
59. Schofer, E., Meyer, J. W. (2005). The worldwide expansion of higher education in the twentieth century. American sociological review, 70(6), 898-920.
60. Stevens, P., Weale, M. (2003): Education and economic growth. London: National Institute of Economic and Social Research.
61. Škrabić Perić, B. (2012): Utjecaj stranog vlasništva banke na njezin kreditni rizik u zemljama srednje i istočne Europe: dinamički panel modeli. Doc. dr. sc. Ekonomski fakultet u Splitu.

62. Škrabić Perić, B., Arnerić, J. (2014). Moj EFST: Ekonomski fakultet Split, Preuzeto 15. Svibanj 2015 iz www.efst.unist.hr: http://www.efst.unist.hr/nastava/nastavniMaterijali/29032_Predavanje82014.pdf
63. Temple, J. (1999): The New Growth Evidence, Journal of Economic Literature, 37 (1), str. 112-156.
64. Vučković, V., Basarac Sertić,M., 2013. "The effect of political institutions on the size of government spending in European Union member states and Croatia". Financial Theory and Practice, 37 (2), 161-179. http://www.fintp.hr/upload/files/ftp/2013/2/vuckovic_basarec.pdf
65. Vught, F. V., Kaiser, F., File, J. M., Gaethgens, C., Westerheijden, D. F. (2010): U-Map: The European classification of higher education institutions.
66. Vukoja, O. (2006): Analiza faktora rasta zemalja srednje i istočne Europe, Preuzeto 10. svibnja 2015 iz Hrčak Portal znanstvenih časopisa Republike Hrvatske - Srce: hrcak.srce.hr/file/63580
67. Wolf, A. (2002): Does education matter? Myths about education and economic growth. Perspectives, 6(4), 115-118.
68. Yan, W., Yudong, Y. (2003): Sources of China's economic growth 1952–1999: incorporating human capital accumulation. China Economic Review, 14(1), 32-52.

Web izvor:

1. http://www.oecd.org/
2. http://en.unesco.org/
3. http://www.unizd.hr/portals/4/nastavni_mat/1_godina/metodologija/METODE_ZNANSTVENIH_ISTRAZIVANJA.pdf
4. http://www.adamsmith.org/wp-content/uploads/2014/07/IncentivetoInvest.pdf
5. http://eacea.ec.europa.eu/Education/eurydice/documents/key_data_series/134HR.pdf
6. http://www.enqa.eu/wp-content/uploads/2013/06/ESG_3edition-2.pdf
7. http://www.pilar.hr/images/stories/dokumenti/studije/10/s_10_vo.pdf
8. http://www.zum.de/whkmla/sp/0910/haeyoon/jhy3.html#ii
9. http://www.ijf.hr/konkurentnost/sosic1.pdf
10. http://www.lingnan.net/jpkc/gjjl/files/kejian/Advanced%20Econometric%20II%EF%BC%9APanel%20Data/CH1%20Static%20Panel%20Data%20Models.pdf

11. http://www.cemfi.es/~arellano/static-panels-class-note.pdf
12. http://statmath.wu.ac.at/~hauser/LVs/FinEtricsQF/FEtrics_Chp5.pdf
13. http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators
14. http://databank.worldbank.org/data/reports.aspx?source=education-statistics-~-all-indicators
15. http://veleri.hr/~ljstambuk/Kvantitativne%20za%20web/Korelacija%20i%20regresija_pod.pdf
16. http://web.efzg.hr/dok/MGR/tsekur/Modeli%20regionalnog%20ekonomskog%20razvoja2.pdf

POPIS TABLICA

Tablica 1: Opis i prikaz varijabli

Tablica 2: Deskriptivna statistika uzorka

Tablica 3: Korelacijska matrica između parova nezavisnih varijabli dok se *GDP* i *GDPPC* promatraju kao zavisne varijable

Tablica 4: Korelacijska matrica između parova nezavisnih varijabli dok se *GDP* i *GDPPC* promatraju kao zavisna varijabla za model prema Keller (2006)

Tablica 5: Rezultati panel analize (*GDP*)

Tablica 6: Rezultati panel analize za model preuzet iz Keller (2006) (GDP)

Tablica 7: Rezultati panel analize (GDPPC)

Tablica 8: Rezultati panel analize za model preuzet iz Keller (2006) (GDPPC)

Tablica 9: Korelacijska matrica između parova nezavisnih varijabli dok se *ENRTER* promatra kao zavisna varijabla

Tablica 10: Rezultati panel analize za četiri modela (*ENRTER*)