LUCASOV PARADOKS

Sajević, Ivana

Master's thesis / Diplomski rad

2020

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:124:076320

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

zir.nsk.hr

UNIVERSITY OF SPLIT

dabar

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U SPLITU

EKONOMSKI FAKULTET

DIPLOMSKI RAD

LUCASOV PARADOKS

Mentor: **Student:**

izv. prof. dr. sc. Josip Visković **Ivana Sajević**

Split, rujan, 2020.

SADRŽAJ

1. UVOD 4

1.1. Problem istraživanja 4

1.2. Predmet istraživanja 6

1.3. Istraživačke hipoteze 7

1.4. Ciljevi istraživanja 8

1.5.Metode istraživanja 9

1.6. Doprinosi istraživanja 9

1.7. Struktura diplomskog rada 9

2. LUCASOV PARADOKS 11

2.1. Pojam i definicija Lucasovog paradoksa 11

2.2. Teorijska objašnjenja Lucasovog paradoksa 11

2.3. Pregled empirijskih istraživanja Lucasovog paradoksa 14

3. ANALIZA INSTITUCIONALNIH FAKTORA- EMPIRIJSKO ISTRAŽIVANJE 26

3.1. Podaci i metodologija 26

3.2. Rezultati istraživanja 30

3.3. Osvrt na hipoteze 30

3.4. Budućnost Lucasovog paradoksa 37

4. ZAKLJUČAK 39

5. LITERATURA 41

6. POPIS TABLICA 45

7. POPIS SLIKA 45

8. PRILOZI 46

9. SAŽETAK 49

10. SUMMARY 50

1. UVOD

1.1. Problem istraživanja

Prema neoklasičnoj teoriji kapital bi se slobodno trebao kretati od bogatih prema siromašnim zemljama. Lucas (1990) je postavio pitanje zašto se kapital ne kreće slobodno kao što neoklasična teorija govori. Promatrao je dvije zemlje koje proizvode isto dobro s istim konstantnim povratom na skali proizvodne funkcije. Ako se proizvodnja po radniku razlikuje između dvije države to je zato što imaju različite razine kapitala po radniku. Prema zakonu opadajućih prinosa to implicira da će granični proizvod kapitala biti veći u manje produktivnim tj. siromašnim ekonomijama. Ako je to slučaj, onda je trgovina kapitalnim dobrima slobodna i konkurentna, a nova ulaganja će se pojaviti samo u siromašnoj ekonomiji te će to vrijediti sve dok se ne izjednači omjer kapitala i rada, a time i nadnice i povrat na kapital. Usporedio je SAD i Indiju i pokazao, ako je neoklasični model zaista točan, granični proizvod kapitala bi u Indiji trebao biti 58 puta veći nego u SAD-u tj. sav kapital iz SAD-a bi trebao ići u Indiju.

Problem istraživanja Lucasovog paradoksa je kako modificirati standardnu neoklasičnu teoriju kako bi paradoks nestao. Teorijska objašnjenja Lucasovog paradoksa mogu se grupirati u dvije kategorije. U prvu grupu spadaju razlike u osnovama koje utječu na strukturu gospodarstva kao što su: tehnološke razlike, faktori koji nedostaju u proizvodnji, vladine politike i institucionalna struktura. Druga grupa se fokusira na nesavršenosti na međunarodnom tržištu kapitala, a to su uglavnom rizik zemlje i asimetrija informacija. Iako kapital ima visok povrat u zemljama u razvoju, tamo ne ide zbog tržišnih neuspjeha ili političkog rizika.

Među alternativnim teorijskim objašnjenjem iza Lucasovog paradoksa, institucionalna kvaliteta empirijski se našla kao vodeće objašnjenje. Odličan primjer u kojem je institucionalna kvaliteta važna za privlačenje stranog kapitala je Intelova odluka da se 1996. godine smjesti u Kostariku. Intel je razmišljao između Brazila, Čilea, Indonezije, Meksika, Filipina i Tajlanda, ali su u posljednjoj fazi procesa odlučivanja u uži izbor uvršteni su Meksiko i Kostarika. Dvije zemlje sa sličnim BDP-om po glavi stanovnika u američkim dolarima (3000 $ u to vrijeme), iako je Meksiko puno veća zemlja. S obzirom na veličinu Intelove investicije u odnosu na veličinu ekonomije, jedna bitna činjenica u procesu odlučivanja bila je dostupnost inženjera i tehnički obučenih radnika, što je u ovom slučaju

pogodovalo Meksiku. Stoga se ne može jasno potvrditi da je ljudski kapital bio odlučujući faktor u Intelovom konačnom izboru. Međutim, ono što je bilo važno je stabilnost Kostarike i niža razina korupcije zbog čega je Intel i odlučio investirati u ovu državu. Jedan od razloga ovakve Intelove konačne odluke je bila i situacija kada je Meksiko rekao da će napraviti „iznimku" od postojećih pravila samo za Intel, za razliku od Kostarike koja je prema svim investitorima imala jednaka pravila (Spaar, 1998). Još jedan primjer važnosti institucionalne kvalitete je porast stranih direktnih investicija (FDI) u Turskoj. Sličan se procvat dogodio i u Portugalu i Grčkoj nakon ulaska u EU. Turska je službene pregovore o ulasku u EU započela 3. listopada 2005. godine. Upravo su ovi službeni pregovori Tursku prisilili da više sliči zemljama EU i to na području bankarskog sektora, antitrastovske politike i regulacije unutarnje politike i to sve kako bi privukla strane investicije. Turska je provela velike institucionalne i ustavne promjene što je rezultiralo porastu FDI sa 1 milijarde $ u 1990-im na više od 5 milijardi $ do kraja 2005. godine (Von Reppert- Bismarck i Champion 2005).

Alfaro, Kalemi-Ozcan i Volosovych (2005) su istražili razdoblje 1970.-2000. godine i pokazali da niska institucionalna kvaliteta objašnjava postojanje Lucasovog paradoksa. Neka od istraživanja ukazuju da bi strana ulaganja mogla biti kanal preko kojeg institucije utječu na dugoročni razvoj. Prema Calvo, Leideman i Reinhart (1996) naglasak stavljaju na vanjske čimbenike, uglavnom na nisku kamatnu stopu u razvijenim zemljama (SAD), zbog čega su se povećala strana ulaganja u zemlje u razvoju tijekom 1990.-ih godina. Niska kamatna stopa u razvijenim zemljama će rezultirati većim ulaganjima u zemlje u razvoju zbog visokih prinosa te na taj način poboljšati ekonomsku sliku gospodarstava. Istraživanje koje su proveli na uzorku zemalja Azije i Latinske Amerike uključujući Argentinu, Brazil, Čile, Kolumbiju, Indoneziju, Maleziju, Meksiko, Filipine i Tajland je pokazalo da je dio porasta priljeva kapitala usmjeren na akumuliranje deviznih rezervi. Od 1990. do 1994. godine udio u rezervama bio je 59 posto u Aziji i 35 posto BDP-a u Latinskoj Americi. Ove su dvije regije akumulirale oko 209 milijardi dolara međunarodnih rezervi u navedenom periodu. Također je pokazano da je u većini zemalja priljev kapitala povezan s rastućim deficitom tekućeg računa. Zemlje poput Brazila i Čilea, koji imaju skromniji deficit tekućeg računa, zabilježile su suficit prije porasta priljeva. Koeficijent investiranja je u periodu 1990.- 1994. godine rastao, a stope štednje padao u polovici promatranog uzorka što implicira da se tržišta kapitala tijekom godina sve više integriraju. Visoke investicije i potrošnja odražavaju se u višim stopama rasta realnog BDP-a.

Prema Obstfeldu i Rogoffu (2000) Lucasov paradoks je povezan sa glavnim „zagonetkama“ u međunarodnoj ekonomiji i financijama. Pod glavnim „zagonetkama“ se smatraju: Feldstein-Horioka zagonetka (postoji visoka korelacija između domaće štednje i investicija), zagonetka domaće pristranosti proizvodnji (ljudi imaju jake preferencije u potrošnji domaćih proizvoda) i zagonetka u dijeljenju rizika (postoji niska korelacija rasta potrošnje među zemljama). Sve ove zagonetke proizlaze iz nedostatka međunarodnih kapitalnih tokova. Na svako od pitanja (zagonetki) postoji nekoliko mogućih odgovora, ma koliko dobri bili, ne mogu u cijelosti objasniti zagonetke, pa rješavanje navedenih i dalje traje. Stoga se još uvijek ne zna što je važnije u objašnjavanju Lucasovog paradoksa, fundamenti (tehnološke razlike, faktori koji nedostaju u proizvodnji, vladine politike i institucionalna struktura) ili tržišni neuspjeh.

1.2. Predmet istraživanja

Prekogranični tokovi kapitala su se znatno povećali i postali su ključni aspekt globalizacije. Povijesno gledano, globalni tokovi kapitala su uglavnom obuhvaćali tokove među razvijenim ekonomijama, međutim posljednjih godina su ti tokovi sve veći među ekonomijama u razvoju. Prema Institutu za međunarodne financije/IIF (2015) kapitalni privatni tokovi na tržištima u nastajanju su u 2013. godini dostigli 1,35 bilijuna dolara. Globalni tokovi FDI su doživjeli snažni porast nakon svjetske ekonomske krize, ali su zemlje u razvoju zabilježile blagi pad FDI zbog skromnog rasta razvijenih ekonomija i poboljšanja tranzicijskih ekonomija. Svjetska banka (2013) je prognozirala da će gospodarstva u razvoju predstavljati 60% globalnog priljeva kapitala do 2030. godine što je samo 20% više nego u protekla četiri desetljeća. Predviđala je da će uz poboljšanu institucionalnu kvalitetu i solidan gospodarski rast te povoljna demografska kretanja, globalni ulagači pokazivati sve veći interes za zemlje u razvoju umjesto malih grupa tržišta u nastajanju koja tradicionalno privlače većinu stranih ulaganja. Međutim, priroda kretanja kapitalnih tokova nije u skladu s predviđanjima. Neke vrste priljeva kapitala (npr. FDI) olakšavaju prijenos upravljačkog i tehnološkog znanja. Ulaganje u portfelj i zajmovi stranih banaka razvijaju domaći financijski sektor u zemljama u razvoju pružajući pristup međunarodnim financijskim tržištima i poboljšavajući regulatorni okvir. Neka istraživanja tvrde da slobodni protok kapitala djeluje kao nagrada za dobre politike i kazna za loše politike koje osiguravaju discipliniranije makroekonomske politike u zemljama u razvoju (Obstfeld 1998).

Predmet istraživanja ovog rada je usko povezan sa problemom istraživanja tj. istražiti empirijske studije za koje se traži rješenje Lucasovog paradoksa.

1.3. Istraživačke hipoteze

Tematika ovog rada će se problematizirati i testirati sljedećim hipotezama:

H1: Kvaliteta institucija je i dalje vodeća varijabla za objašnjenje Lucasovog paradoksa

Kvaliteta institucija je, kao što je ranije navedeno u radu, jedan od ključnih faktora prilikom objašnjenja i rješavanja Lucasovog paradoksa. Kvaliteta institucija danas se prati putem pokazatelja upravljanja Svjetske banke (engl. - World Government Indicators - WGI). Šest je veličina prema kojima se određuje kvaliteta upravljanja: glasanje i odgovornost, politička stabilnost i odsutnost nasilja, učinkovitost vlade, regulatorna kvaliteta, vladavina zakona i kontrola korupcije. Podaci za 200 zemalja dostupni su za razdoblje od 1996. do 2018. godine. Glavna hipoteza pokušat će se potvrditi s dvije pomoćne hipoteze.

H 1.1.: Regulatorna kvaliteta, vladavina zakona i kontrola korupcije djeluju na kvalitetu institucija i na povećavanje priljeva kapitala

Regulatorna kvaliteta je sposobnost vlade da formulira i provodi zdrave politike i propise koji dopuštaju i promiču razvoj privatnog sektora. Vladavina zakona govori o tome u kojoj mjeri agenti imaju povjerenja i poštuju se pravila društva, posebno kvaliteta izvršenja ugovora, imovinskih prava, policije i sudova kao i vjerojatnosti kriminala i nasilja. Kontrola korupcije prikazuje percepciju u kojem se javna vlast koristi u privatnom interesu, uključujući političku i administrativnu korupciju. Iako se postojeća literatura uglavnom fokusira na učinke korupcije, ovom hipotezom će se dodatno uz kontrolu korupcije testirati i regulatorna kvaliteta, vladavina zakona te istražiti kako one utječu na odluku stranih investitora o poduzimanju investicijskih projekata u određenoj zemlji. Učinak institucija na ulaganja, bilo domaća ili strana se mogu povezati s dva različita kanala. Prvo, „loše“ institucije mogu djelovati kao porez povećavanjem troškova poslovanja. Drugo, nesavršeno provođenje ugovora također može povećati neizvjesnost u pogledu budućih povrata i tako negativno utjecati na razinu ulaganja. Npr. korupcija može odvratiti ulaganja povećanjem troškova poslovanja jer ulagači trebaju podmićivati službenike kako bi se dobile dozvole, dok će

povećana regulatorna kvaliteta ili kvalitetni zakonski okviri pozitivno utjecati na privlaćenje stranih investicija (Daude i Stein, 2007).

H 1.2.: Doing business indikator djeluje na kvalitetu institucija i na povećavanje priljeva kapitala

Doing business pruža objektivne mjere poslovnih propisa i njihove primjene u 190 gospodarstava i odabranih gradova na regionalnoj razini. Projekt Doing business je pokrenut 2002. godine od strane Svjetske banke te promatra domaće male i srednje tvrtke i mjeri propise koji se na njih primjenjuju u njihovom životnom ciklusu. Prikupljajući i analizirajući sveobuhvatne i kvantitativne podatke za usporedbu okruženja poslovne regulacije za čitava gospodarstva, doing business potiče gospodarstva da se natječu za učinkovitiju regulaciju. Doing business mjeri opće poslovno okruženje. Zasniva se na konkretnim pokazateljima koji ispituju brojne aspekte poslovnog okruženja poput toga kako je lako pokrenuti posao, koliko je lako plaćati porez i lakoće obavljanja međunarodne trgovine. Prema Djankov, McLiesh i Ramalho (2006), postoji veza između Doing business indikatora i ekonomskog rasta. Razlog njihovog istraživanja je razlika između razina dohodaka među zemljama. Doing business pokazatelj pruža širok spektar konkretnih mjera kako vladine politike trebaju utjecati na poslovanje firmi. Drugim riječima, lakše je postaviti ciljeve koliko je dana potrebno za pokretanje novog posla, koliko je dokumenata potrebno potpisati za izvoz kontejnera i koliko je malim firmama potrebno da ispune porez na dohodak nego da zahtijevaju uvođenje demokracije ili poboljšanja u funkcioniranju pravosudnog sustava. Hipotezom H 1.2. će se testirati odnos između doing business indikatora i priljeva kapitala u zemlju.

1.4. Ciljevi istraživanja

Cilj ovog rada je istražiti ulogu različitih teorijskih objašnjenja u nedostatku protoka kapitala iz bogatih u siromašne zemlje. Nakon što će se teorijski objasniti uzroci spomenutih tijekova, po uzoru na istraživanje Alfaro, Kalemi-Ozcan i Volosovych (2005) u ovome radu cilj je uraditi dodatno istraživanje na što većem uzorku zemalja na globalnoj razini u ovisnosti o dostupnosti podataka.

1.5. Metode istraživanja

U ovom radu će se koristiti više različitih metoda ovisno o tome radi li se o teorijskom ili empirijskom dijelu rada. U teorijskom dijelu koristit će se induktivna metoda gdje će se na temelju pojedinačnih činjenica donijeti konačan zaključak te deduktivna metoda kojom se na temelju općih znanja dolazi do spoznaje posebnog i pojedinačnog. Koristit će se i metoda analize kojom će se nastojati složeni pojmovi i zaključci raščlaniti na jednostavnije dijelove i metoda sinteze kojom će se jednostavniji sudovi sintetizirati u složenije. Komparativnom i deskriptivnom metodom će se jednostavnim usporedbama i opisivanjem analizirati pokazatelji dok će se metodom klasifikacije i kompilacije izdvajati opći pojmovi te stavovi i zaključci. U empirijskom dijelu rada će se koristiti metoda višestruke regresije kao jedna od metode linearne regresije. Prednost ove metode je što može koristiti više podataka i informacija koristeći se većim nizom varijabli i zbog toga što se varijable tijekom vremena mijenjaju.

1.6. Doprinosi istraživanja

Ovim istraživanjem želi se doprinijeti postojećoj empirijskoj literaturi koja se bavi pojmom i rješavanjem Lucasovog paradoksa. Naime, postoje mnoga istraživanja koja su utvrdila da je kvaliteta institucija ključna za rješavanje Lucasovog paradoksa. Kvaliteta institucija se može mjeriti preko šest indikatora od čega su u ovome radu izdvojena tri: regulatorna kvaliteta, vladavina zakona i kontrola korupcije. Jedan dodatni doprinos ovom istraživanju je istraživanje doing business indikatora te njegov utjecaj na kvalitetu institucija. Dosadašnja istraživanja su obuhvaćala period od 1970. do 2000. godine, a dodatni doprinos ovog istraživanja je istraživanje perioda nakon 2000. godine.

1.7. Struktura diplomskog rada

Rad se sastoji od četiri dijela.

U uvodnom dijelu rada definirat će se problem i predmet istraživanja. Nakon toga odredit će se ciljevi istraživanja te će se postaviti određene pretpostavke. Slijedi kratko objašnjenje

metoda korištenih u radu. Prvo poglavlje završava osvrtom na potencijalni doprinos istraživanja.

Drugi dio rada će prikazati teorijski pristup Lucasovom paradoksu te dosadašnja empirijska istraživanja. U ovom dijelu će se govoriti o kategorijama u koje se mogu grupirati teorije koje objašnjavaju paradoks. Također će se osvrnuti na istraživanje provedeno za razdoblje od 1970. do 200. godine.

U trećem dijelu rada će se prikazati empirijsko istraživanje provedeno za razdoblje nakon 2000. godine, prikazati metodologija koja se koristila u istraživanju te će se na kraju osvrnuti na postavljene hipoteze koje će se ili prihvatiti ili odbaciti. Spomenut će se i budućnost Lucasovog paradoksa.

U četvrtom dijelu, zaključku, ukratko se osvrće na ključne teorijske spoznaje i rezultate vlastitog istraživanja. Također se u ovom dijelu rada nalazi popis literature, popis grafikona i tablica.

2. LUCASOV PARADOKS

2.1. Pojam i definicija Lucasovog paradoksa

Lucasov paradoks odnosi se na promatranje protoka kapitala između bogatih i siromašnih zemalja koji je daleko niži od protoka predviđenih neoklasičnom teorijom tj. kapital se ne kreće slobodno prema siromašnim zemljama kao što neoklasična teorija predviđa te se zbog toga teško osloniti na navedeni model.

Tijekom prve faze financijske globalizacije između 1880. i 1914. godine, međunarodna mobilnost kapitala bila je visoka kao i danas. Obrasci kretanja međunarodnih kapitalnih tokova razlikuju se između dva razdoblja uglavnom neograničene mobilnosti kapitala. Prije Prvog svjetskog rata kapitalni tokovi bili su pretežno jednosmjerni u smislu da je kapital tekao iz bogatih gospodarstava Europe ka siromašnijim. Kao posljedica toga, bogate države su izgradile značajne neto pozicije inozemne imovine od oko 20% svog ukupnog BDP-a, a omjer stranog kapitala i proizvodnje do 1914. godine u prosjeku je bio viši od 100 % u zemljama u razvoju. U suvremenoj globalizaciji bruto mobilnost kapitala jednako je visoka, ali ne dovodi do značajnih neto tokova kapitala između bogatih i siromašnih zemalja. Kao rezultat, Lucasov paradoks kapitalnih tokova između bogatih i siromašnih izraženiji je sada nego u prvoj globalizaciji (Bilal, 2017).

2.2. Teorijska objašnjenja Lucasovog paradoksa

Teorijski pristup Lucasovog paradoksa može se svrstati u dvije glavne skupine (Alfaro et al., 2008). Prva skupina pokušava objasniti paradoks kroz ekonomske pokazatelje (fundamente) kao što su: faktori koji nedostaju u proizvodnji, vladine politike i institucionalna struktura. Druga skupina pokušava objasniti paradoks kroz nedostatke na međunarodnom tržištu i to kroz asimetriju informacija i rizik zemlje.

Ekonomski pokazatelji (fundamenti)

- Faktori koji nedostaju u proizvodnji

Jedno od objašnjena nedostatka protoka kapitala iz bogatih u siromašne zemlje je postojanje faktora kao što su ljudski kapital i zemlja koji pozitivno utječu na povrat

kapitala, ali ih uglavnom zanemaruje konvencionalni neoklasični pristup. Na primjer, ako ljudski kapital pozitivno utječe na povrat kapitala, u zemlje s manjim udjelom ljudskog kapitala će ići i manje kapitala.

- Vladine politike

  Vladine politike mogu biti još jedna prepreka protoku kapitala i povrata na kapital. Na primjer, razlike u poreznim politikama među državama mogu dovesti do znatnih razlika u omjerima kapitala i rada. Inflacija se nekada može promatrati kao porez i zbog toga može umanjiti povrat na kapital. Uz to, vlada može ograničiti protok kapitala nametanjem kapitalne kontrole.

- Institucionalna struktura

  Institucije su pravila igre u društvu. Oni se sastoje od neformalnih ograničenja (tradicije i običaji) i formalnih pravila (pravila, zakoni, ustav). Oni oblikuju strukturu gospodarstva. Podrazumijeva se da institucije utječu na investicijske odluke na način da svojim djelovanjem mogu zaštititi vlasnička prava poduzetnika protiv vlade ili sprječavanjem pojedinaca da blokiraju usvajanje novih tehnologija. Slaba vlasnička prava zbog loših institucija mogu dovesti do nedostatka proizvodnih kapaciteta ili nesigurnosti investiranja u gospodarstvo.

Nesavršenost na međunarodnom tržištu kapitala

- Asimetrične informacije

  Problem asimetrije informacija je svojstven tržištima kapitala. Asimetrija informacija može biti ex-ante (nepovoljna selekcija) i ex-post (moralni hazard). Nepovoljan selekcija povezana je s asimetričnim informacijama koje se javljaju prije nastanka transakcije. Visoko rizični tražitelji najintenzivnije traže npr. kredit. Budući da negativna selekcija povećava šansu davanja kredita s velikim kreditnim rizikom, kreditori mogu odlučiti ne dati kredit nikome iako na tržištu ima nerizičnih tražitelja kredita. Moralni hazard nastaje nakon nastanka transakcije. Zajmodavac se upušta u rizik da će zajmoprimac odobrenim kreditom poduzeti radnje koje nisu prihvatljive s njegove točke gledišta. Prema tome zajmodavac može odlučiti da radije neće dati kredit. Prema asimetričnim informacijama, implikacije neoklasičnog modela u vezi s protokom kapitala obično nisu održive. Na primjer, u modelu s moralnim hazardom, gdje zajmodavci ne mogu nadzirati ulaganje

dužnika, ulaganje siromašnih zemalja po stanovniku pozitivno ovisi o bogatstvu po glavi stanovnika. Ako strani investitori nisu dovoljno informirani o domaćem tržištu, oni imaju tendenciju premalo ulagati.

- Rizik zemlje

Rizik zemlje predstavlja svaku situaciju u kojoj država koja ne izvršava ugovore o zajmu sa strancima, oduzima inozemnu imovinu koja se nalazi unutar njezinih granica ili sprječava domaće stanovnike da u potpunosti ispunjavaju obveze prema stranim ugovorima. Lucas je pozivajući se na primjer Indije, odbacio rizik zemlje kao objašnjenje paradoksa tj. protoka kapitala iz bogatih u siromašne zemlje jer su se ulagači u Indiji suočili s istom regulacijom i pravilima kao i ulagači u Velikoj Britaniji (Alfaro et. al. 2008).

Lucasov osnovni rad bio je reakcija na uočene trendove u međunarodnim razvojnim naporima tijekom 20.-tog stoljeća. Regije koje karakterizira siromaštvo, poput Južne Azije i Afrike, dobile su posebnu pozornost s obzirom na nedovoljna ulaganja koja je predvidio Lucas. Afričke zemlje sa svojim siromašnim stanovništvom i bogatim prirodnim resursima su primjer koje bi pod neoklasičnom pretpostavkom mogle ponuditi izuzetno visoke povrate kapitala. Oskudni strani kapital koji afričke zemlje dobivaju izvan dobrotvornih organizacija multinacionalnih korporacija otkriva stvarnost današnjih globalnih tokova kapitala, (Montiel, 2006). Autori su u posljednje vrijeme svoja objašnjenja za paradoks usredotočili na Lucasovu prvu kategoriju objašnjenja kao vodeću ulogu tj. institucionalnu stabilnost te se pokazalo da je količina stranih direktnih investicija u velikoj mjeri povezana sa snagom infrastrukture i stabilnošću vlade u pojedinim zemljama (Daude, 2007). Iako je Lucasova izvorna hipoteza široko prihvaćena kao opis modernog razdoblja u povijesti, paradoks se ne pojavljuje tako jasno prije 20.-tog stoljeća. Na primjer, kolonijalno doba se ističe kao doba nesmetanih tokova kapitala, a sustav imperijalizma stvorio je ekonomske uvjete posebno pogodne za kretanje kapitala prema pretpostavkama klasične ekonomije. Britanija je na primjer bila u stanju dizajnirati, nametati i kontrolirati kvalitetu institucija u svojim kolonijama kako bi iskoristile visoke povrate kapitala u novom svijetu (Schularick, 2008). Prema Williamson (2002), detaljno je istražio preokret paradoksa u kolonijalnom kontekstu. Iako Lucas to nije naglasio, Williamson tvrdi da je nesmetana migracija radne snage jedan od načina na koji kapital teče prema građanima zemalja u razvoju. Struktura carstva bila je posebno važna za olakšavanje jeftine međunarodne migracije. Primjerice u 17. i 18. stoljeću Engleska je

poticala svoje građane da se presele u Ameriku koja je bila oskudna radnom snagom. Iako je Britanija omogućila slobodan protok kapitala iz starog u novi svijet, uspjeh američkog poduzetništva nakon američke revolucije dobar je primjer uloge institucionalnih i pravnih okvira za olakšavanje kontinuiranog protoka kapitala. Rani američki ekonomski razvoj prije i nakon revolucije doveo je do obrnutog slučaja Lucasovog pradoksa. Čak i nakon što je prosječna razina dohotka u Americi premašila britansku, institucije koje su se izvozile imperijalizmom i pravnim okvirom, omogućile su dugoročne tokove kapitala iz Europe u Ameriku (Ferguson, 2011).

2.3. Pregled empirijskih istraživanja Lucasovog paradoksa

Postojeća empirijska literatura otkriva da se za rješavanje Lucasovog paradoksa koriste dvije analize, analiza graničnog proizvoda kapitala (engl. Marginal product of capital - MPK) analiza čiji je cilj izravno mjerenje graničnog proizvoda kapitala i regresijska analiza. Analiza zasnovana na MPK pomaže odgovoriti zašto relativno bogate zemlje imaju i relativno visoke granične proizvode kapitala, a metoda regresijska analiza pokušava identificirati determinante priljeva kapitala.

Neka od istraživanja provedena analizom graničnog proizvoda kapitala pomažu u razumijevanju međunarodnog toka kapitala. Neka od njih sugeriraju da tijek kapitala ide, ako ništa drugo, prema relativno niskim prinosima. Umjesto da ova analiza riješi paradoks, ona ga je samo preimenovala iz „zašto kapital ne ide u siromašne zemlje“ u „zašto kapital ide u zemlje s niskim prinosom“. Objašnjenje toga leži u činjenici da analiza MPK ne obuhvaća na odgovarajući način sve važne čimbenike koji utječu na međunarodne kapitalne tokove. Analizom graničnog proizvoda kapitala su se bavili Caselli i Feyrer (2007) i Lowe et. all. (2012) čiji će se kratki zaključci navesti u daljnjem tekstu. Oni pokušavaju objasniti razne čimbenike koji se koriste u analizi MPK te pokušavaju objasniti međunarodni tok kapitala. Međunarodni tokovi kapitala koje su promatrali nisu u skladu s predviđanjima jer kapital ide iz zemalja s visokim prinosom u zemlje s niskim prinosom. Pokušali su provjeriti jesu li procjene MPK u pozitivnoj korelaciji s međunarodnim priljevom kapitala u razdoblju od 1995. do 2007. godine. Dijagram rasipanja se koristi za provjeru protoka međunarodnog kapitala iz zemalja s niskim MPK u zemlje s visokim MPK. Ako promatranje za neku zemlju leži iznad nulte crte to znači da su priljevi veći od odljeva što ukazuje na priljev kapitala u

zemlju, a ako promatranje za neku zemlju leži ispod nulte crte to znači da su odljevi veći od priljeva što ukazuje na odljev kapitala iz zemlje. Povezanost između unutarnji direktnih investicija i MPK (slika 1.) pokazuje da kapital teče u zemlje s visokim povratom poput Konga (COG) i El- Salvadora (SLV) što je u skladu s pretpostavkom standardne teorije.

Slika 1: Dijagram rasipanja „naive“ MPK i unutarnjih direktnih investicija

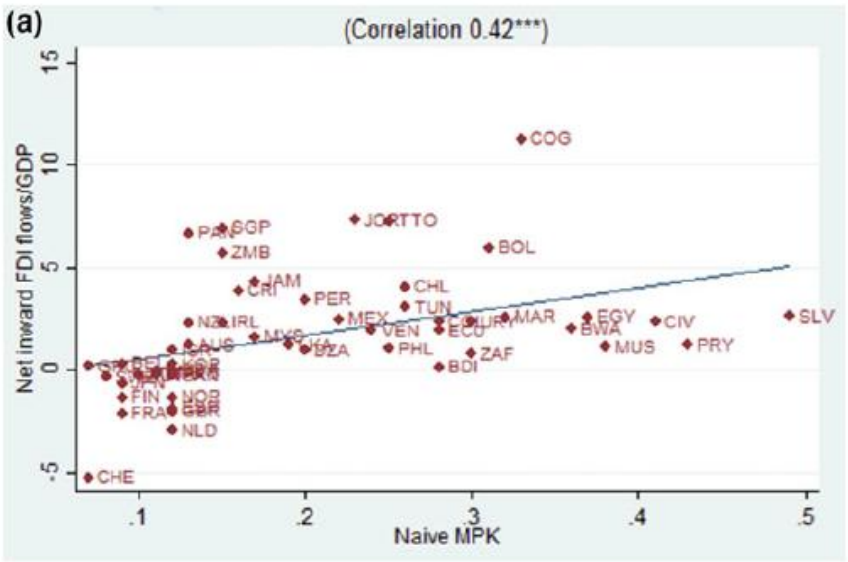

Izvor: https://link.springer.com/book/10.1007%2F978-981-13-9069-2

Standardni izračun graničnog proizvoda kapitala (engl. MPK) tzv. „naive“ procjena glasi MPKN = $\alpha_w \frac{Y}{K}$ pri čemu je Y bruto domaći proizvod (BDP), K je kapital, a α je bruto izračun udjela u kapitalu. Tvrdili su da bruto izračun udjela u kapitalu dovodi do precijenjivanja stvarnog MPK te su stoga procjenu udjela kapitala izmijenili i podijelili na obnovljivi kapital α_{rk} (oprema i strojevi) i neobnovljivi kapital α_{nk} (zemljište i prirodni resursi). S druge strane kada se koristi izmijenjena procjena MPK kod Caselli i Feyrer, čini se da kapital ide prema relativno niskim prinosom (slika 2.) uključujući Zambiju (ZMB) i Trinidad i Tobago (TTO).

Slika 2: Dijagram rasipanja izmijenjenog MPK i unutarnjih direktnih investicija

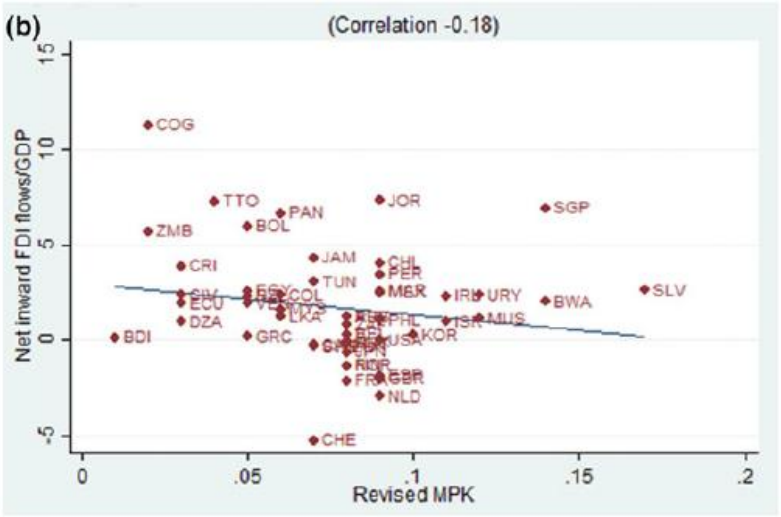

Izvor: https://link.springer.com/book/10.1007%2F978-981-13-9069-2

Međutim, povezanost između izmijenjene procjene MPK i tijeka stranih direktnih investicija je slaba (-0,18). Stoga se iz njihovog dijagrama rasipanja može zaključiti da povezanost između izmijenjenih procjena MPK i podataka o protoku kapitala pokazuje da su tokovi kapitala iz bogatih u siromašne zemlje znatno niži od onoga što predviđa teorija.

Literatura koja se temelji na metodi regresijske analize razmatra širi skup varijabli kao odrednice priljeva kapitala, što se ne može lako objasniti u MPK analizi. Uzimajući u obzir karakteristike varijabli i njihov utjecaj na priljev kapitala, literaturu koja se temelji na metodi regresijske analize može se podijeliti u tri kategorije, a to su ekonomske osnove (fundamenti), nedostaci na međunarodnom tržištu i institucionalna struktura. Alfaro et all. (2008) su u svome istraživanju u regresijski model uključili kvalitetu institucija i tvrdili da razlike u njihovoj kvaliteti određuju priljev kapitala i da se tako može u potpunosti objasniti Lucasov paradoks. Postoji pozitivna i statistički signifikantna korelacija između priljeva kapitala i prihoda po glavi stanovnika nakon što se kontrolira kvaliteta institucija.

Međunarodna financijska statistika (engl. IFS) koju je izdao Međunarodni monetarni fond (engl. IMF) je standardni izvor podataka za godišnje priljeve kapitala. Glavne kategorije priljeva kapitala su strane direktne investicije, portfeljna ulaganja i priljev duga. Strane direktne investicije uključuju greefield ulaganja (izgradnja novih tvornica), dionički kapital, reinvestiranu dobit, financijske instrumente i drugi kapital. Ulaganje u portfelj uključuje dionice, udjele u dionice i slične dokumente koji označavaju vlasništvo nad kapitalom. U regresijskoj analizi nije pravljena razlika između manjinskih i većinskih dioničara jer ta

razlika ne utječe na rezultate analize te se u analizi koristio ukupni strani kapital koji je zbroj priljeva izravnih i portfeljnih ulaganja. Ukupni kapital (izravni i portfeljni) kod zemalja u razvoju uopće nije mali. U zemljama u razvoju prosječni priljev stranih direktnih investicija po glavi stanovnika porastao je za 6,2% u posljednjih 30-ak godina i postao glavni izvor privatnog kapitala tijekom 1990-ih godina. Prosječni priljev portfelj ulaganja po glavi stanovnika porastao je za samo 3,3%. Kraay, Loayza, Server i Ventura (2000, 2005) (KLSV) i Lane i Milesi- Feretti (1999, 2001) (LM) konstruirali su procjene strane imovine i obveza i njihovih potkomponenata za različite zemlje 19070.-ih, 1980.-ih i 1990.-ih godina i time bolje praćenje zemalja i njihove vanjske pozicije. LM procjena uzima podatke o stanju dionica u portfelju i podatke o stranim direktnim investicijama iz međunarodne financijske statistike koju je napravio MMF. Kako bi dobili stvarne procjene stranih direktnih investicija kumulirali su tokove kapitala i prilagodili ih promjenama tečaja. Dionice su prilagođavali domaćem tržištu dionica prema vrijednosti tj. tečaju američkog dolara na kraju godine. KLSV se protivi vrednovanju dionica koristeći cijene dionica na burzi, umjesto toga koriste cijene investicijske robe u lokalnoj valuti te i oni tokove prilagođavaju promjenama tečaja. KLSV i LM procjene su kvalitetnije jer autori izuzetno paze na prikupljanje i „pročišćavanje“ podataka IFS-a. Ova empirijska analiza je koristila podatke o priljevima kapitala iz tri različita izvora (IMF, KLSV, LM). Slika 3 prikazuje deskriptivnu statistiku na uzorku od 81 zemlje u razdoblju 1970.-2000. godine prema IMF podacima, 58 zemalja u razdoblju 1970.- 1997. godine prema KLSV podacima i 56 zemalja u razdoblju 1970.- 1998. godine prema LM podacima. Osnovni uzorak zemalja je odabran prema dostupnosti podataka za određene zemlje u određenom vremenskom razdoblju pri čemu je zavisna varijabla prosječni priljev direktnih i portfelj ulaganja po glavi stanovnika. Prosječni priljev direktnih i portfolio ulaganja po glavi stanovnika je sa srednjom vrijednosti od 117,34, standardnom devijacijom 170,29 za IMF podatke, srednjom vrijednosti od 38,57, standardnom devijacijom 59,27 za KLSV podatke i srednjom vrijednosti 202,29, standardnom devijacijom 322 za LM podatke.

Slika 3: Deskriptivna statistika

	Mean	Std.Dev.	Min	Max
IMF, IFS Capital Flows Data: Base Sample of 81 Countries				
Average Inflows of Capital per capita, 1970–2000	117.34	170.29	–0.29	722.72
GDP per capita in 1970 (PPP 1996)	5.86	4.53	0.61	16.49
Average Institutional Quality, 1984–2000	6.94	1.50	4.31	9.69
Average Years of Schooling, 1970–2000	5.53	2.92	0.48	11.41
Average Distantness, 1970–2000	7.93	2.11	5.45	13.75
Average Restrictions to Capital Mobility, 1970–2000	0.52	0.27	0.00	0.97
KLSV Capital Flows Data: Base Sample of 58 Countries				
Average Inflows of Capital per capita, 1970–1997	38.57	59.27	–29.32	181.16
GDP per capita in 1970 (PPP 1990)	5.17	4.07	0.85	15.74
Average Institutional Quality, 1984–1997	6.92	1.64	4.35	9.65
Average Years of Schooling, 1970–1997	5.59	2.60	1.78	11.41
Average Distantness, 1970–1997	8.16	1.96	5.75	13.50
Average Restrictions to Capital Mobility, 1970–1997	0.54	0.27	0.00	1.00
LM Capital Flows Data: Base Sample of 56 Countries				
Average Inflows of Capital per capita, 1970–1998	202.29	322	0.80	1309.30
GDP per capita in 1970 (PPP 1996)	6.60	5.25	0.56	23.39
Average Institutional Quality, 1984–1998	7.12	1.52	4.46	9.67
Average Years of Schooling, 1970–1998	5.83	2.44	2.00	11.41
Average Distantness, 1970–1998	8.28	2.20	5.43	13.80
Average Restrictions to Capital Mobility, 1970–1998	0.51	0.29	0.00	0.98

Izvor: Alfaro et. al. (2008), „Why Doesn't Capital Flow from Rich to Poor Countries? An Empirical Investigation“, raspoloživo na: https://www.nber.org/papers/w11901

Za prikazivanje fundamenata (osnova) koristit će se logaritam prosječne godine ukupnog školovanja i prosječna institucionalna kvaliteta. Međutim, mjerenje kvalitete institucija je težak zadatak, a mjeri se godišnjim indeksom koristeći se Međunarodnim vodičem za rizik zemlje (engl. The International Country Risk Guide - ICRG). Indeks je zbroj indeksa investicijskog portfelja, stabilnosti vlade, unutarnjih sukoba, vanjskih sukoba, nekorumpiranosti, nemilitarizirane politike, zaštite od vjerskih tenzija, zakona i reda, zaštite od etničkih tenzija, demokratske odgovornosti i birokratske kontrole. Ovaj indeks uzima vrijednosti 0-10 za svaku zemlju prilikom čega viši indeks znači niži rizik. Niska razina ljudskog kapitala i slabe institucije smanjuju produktivnost te se stoga očekuje da ove varijable budu signifikantne. Kao što je vidljivo na slici 1, BDP po glavi stanovnika (PPP) u 1970.-oj godini, prosječna institucionalna kvaliteta i prosječne godine školovanja pokazuju velike razlike. BDP po glavi stanovnika u 1970.-oj godini varira od 500 PPP $ do 23 000 PPP $, a najobrazovanija zemlja je sa 11 godina školovanja.

Varijabla koja se naziva „udaljenost“ predstavlja ponderirani prosjek udaljenosti od glavnog grada određene zemlje do glavnih gradova drugih zemalja koristeći udjele u BDP-u kao pondere. Prema Kalemli-Ozcan, Sorensen i Yosha (2003), kreiran je Arcview softwer za izračun udaljenosti. Npr. Kongo je bliži ekvatoru te će stoga biti udaljeniji od ostalih zemalja gledajući prosječnu udaljenosti, a SAD će biti zemlja najmanje udaljenosti. Na slici 3 se vidi da je zemlja koja je u najnepovoljnijem položaju u odnosu na ovu varijablu 3 puta udaljenija od zemlje koja je najmanje ugrožena.

Na slici 4 se mogu vidjeti rezultati istraživanja ostalih predloženih varijabli za objašnjenje paradoksa kako za uzorak „cijeli svijet“ tako i za „osnovni“ uzorak. Uzorci „cijeli svijet“ se mijenjaju za svaku varijablu zbog dostupnosti podataka. U stupcu 1 su dodane prosječne godine školovanja što na kraju ispada da je beznačajno. U stupcu 2 je dodana varijabla udaljenost koja se također pokazuje beznačajnom. Stupac 3 prikazuje ulogu ograničenja mobilnosti kapitala koja je negativna na razini signifikantnosti od 1%. Međutim, log BDP-a po glavi stanovnika je pozitivan i značajan pa stoga ograničenje mobilnosti kapitala ne može objasniti paradoks. Stupac 4 i 5 predstavljaj istu analizu samo za „osnovne“ uzorke dobivajući slične rezultate. U stupcu 7 su rezultati višestruke regresije pri čemu paradoks nestaje zbog uključivanja indeksa kvalitete institucija. Ograničenja u mobilnosti kapitala su također važna, ali ne mogu objasniti paradoks. Kvaliteta institucija je važna za objašnjenje paradoksa i uvijek je značajna na razini od 1%. (Alfaro et all., 2008).

Slika 4: Metoda najmanjih kvadrata- IMF podaci

	Whole World (1)	Whole World (2)	Whole World (3)	Base Sample (4)	Base Sample (5)	Base Sample (6)	Base Sample (7)	Base Sample (8)
Log GDP per capita (PPP) in 1970	1.03*** (0.22)	0.99*** (0.17)	0.82*** (0.14)	1.14*** (0.24)	1.11*** (0.19)	0.91*** (0.16)	0.13 (0.18)	
Log GDP per capita (1996 $) in 1970								0.20 (0.15)
Average Institutional Quality, 1984–2000							0.65*** (0.15)	0.59*** (0.14)
Log Average Years of Schooling, 1970–2000	0.12 (0.16)			0.06 (0.18)			–0.10 (0.15)	–0.18 (0.19)
Log Average Distantness, 1970–2000		–0.68 (0.69)			–0.58 (0.72)		–0.29 (0.58)	–0.31 (0.60)
Average Restrictions to Capital Mobility, 1970–2000			–1.54*** (0.53)			–1.83*** (0.60)	–1.23*** (0.46)	–1.17*** (0.44)
R^2	0.39	0.38	0.42	0.39	0.40	0.45	0.55	0.55
Countries	92	98	97	81	81	81	81	81

Izvor: Alfaro et. al. (2008), „Why Doesn't Capital Flow from Rich to Poor Countries? An Empirical Investigation“, raspoloživo na: https://www.nber.org/papers/w11901

Uz prethodno dvije detaljnije analize, mnogi drugi autori su također istraživali determinante kretanja kapitala. Njihovi kratki zaključci su izneseni u daljnjem tekstu.

Abiad et. al. (2009) su na uzorku zemalja iz Europe, Sjeverne i Južne Amerike i Azije u periodu 1975.- 2004. godine koristili panel metodu i zaključili da u Europi viša financijska integracija uzrokuje da kapital teče iz bogatih u siromašne zemlje. Financijsku integraciju su mjerili neto udjelom strane imovine i BDP-om po glavi stanovnika pri čemu je zavisna varijabla stanje tekućeg računa, a kontrolne varijable su rast BDP-a po glavi stanovnika i fiskalna ravnoteža.

Azemar i Desbordes (2013) su na uzorku od 60 zemalja u periodu 1970.- 1988. godine metodom najmanjih kvadrata donijeli zaključak da institucionalna kvaliteta ne rješava Lucasov paradoks. Institucionalna kvaliteta je analizirana pomoću zavisne varijable priljev privatnog kapitala po glavi stanovnika, a kontrolne varijable su godine školovanja, udaljenost i ograničenja računa kapitala.

Fernandez-Arias (1996) je na uzorku od 13 zemalja u periodu 1989.- 1999. godine (kvartalno) pomoću metode najmanjih kvadrata zaključio da je priljev kapitala u zemlje u razvoju rezultat nižih kamatnih stopa u razvijenim zemljama. Zavisna varijabla u njegovoj analizi je bio

priljev portfelja, a kontrolne varijable su bile kamatna stopa razvijenih zemalja i kamatna stopa zemalja u razvoju.

Okada (2013) je na uzorku od 112 zemalja u periodu 1985.- 2009. godine panel metodom zaključio da veća razina institucionalne kvalitete uzrokuje veći priljev kapitala ukoliko je račun kapitala otvoren. Ovisnost otvorenosti računa kapitala i indeksa kvaliteta institucija je istraživan pomoću zavisne varijable strane direktne investicije po glavi stanovnika i privatni kapital po glavi stanovnika, a kontrolne varijable su BDP po glavi stanovnika, obrazovanje i inflacija.

Portes i Rey (2005) su na uzorku od 14 zemalja u periodu 1989.- 1996. godine dokazali da asimetrija informacija ima negativan utjecaj na priljev kapitala. U svom istraživanju im je zavisna varijabla bio zbroj kupljenih i prodanih dionica, a kontrolne varijable su bile različite determinante koje dovode do asimetrije informacija, udaljenost (koja je izračunata kao ponderirani prosjek udaljenosti od glavnog grada određene zemlje do glavnih gradova drugih zemalja koristeći udjele u BDP-u kao pondere) i cijena financijskih transakcija.

Empirijska literatura nudi različite izvore kapitala kao zavisne varijable, što je jedan od razloga drukčijih rezultata analiza u literaturi. U slučaju stranih direktnih investicija (FDI), bruto priljev FDI i neto priljev FDI se koriste često te mogu rezultirati različitim argumentima u korist svakoga u ovisnosti o kontekstu analize. Iako se čini da se bruto priljevi koriste češće u empirijskoj literaturi, jednako tako se koriste i neto priljevi FDI. Prema definicijama koje koriste Svjetski pokazatelji razvoja i Konferencija Ujedinjenih naroda o trgovini i razvoju (engl. United Nations Conferences on Trade and Development- UNCTAD), neto priljev stranih direktnih ulaganja odgovara definiciji MMF-a gdje je neto priljev stranih ulaganja zbroj vlastitog kapitala izravnog ulaganja, zarade od reinvestiranja i ostalog dugoročnog i kratkoročnog kapitala prikazanog u platnoj bilanci.

Mnoga je literature koja govori o utjecaju institucionalne kvalitete na priljev stranih direktnih investicija. Oneal (1994), Jensen (2003) i Li (2009) su stavljali naglasak na političke režime kao što su demokracija i autokracija, Wei (2000) je stavljao naglasak na korupciju u vladi, Asidev (2002) je stavljao naglasak na političku stabilnost. Međutim, jako je malo istraživanja koja uspoređuju važnost utjecaja političkog i institucionalnog rizika na FDI. Prema Benassy-Owere et. al. (2007), koji su koristili podatke za 83 zemlje u razvoju u periodu 1984.- 2004. godine, ispitivali su učinke različitih oblika političkih rizika na strana ulaganja. Važno otkriće njihove analize je da, u usporedbi s drugim institucionalnim i političkim rizicima za strane

direktne investicije, rizik izvlaštenja (vjerojatnost 100%-tnog gubitka uloženog kapitala) je najčešće najvažnija briga stranih ulagača. Ovo otkriće pomaže razumjeti postupak donošenja odluka stranih ulagača i kako oni percipiraju pojedinačne političke rizike prilikom donošenja odluka o stranim ulaganjima na stranim lokacijama. Asideu et. al. (2009) u svom istraživanju su također otkrili da rizik izvlaštenja smanjuje neto protok stranih ulaganja. Otkrili su da je negativan odnos jači za zemlje koje primaju manje inozemne pomoći te otkrivaju da se strana pomoć koristi kao poluga za smanjenje opasnosti od izvlaštenja od strane vlade domaćina.

Busse i Hefeker (2007) su ispitivali pojedinačne učinke svake varijable iz vodiča za institucionalni rizik zemlje (engl. ICRG) bilo institucionalne ili političke te nisu pronašli statistički značajne učinke rizika izvlaštenja na neto priljeve FDI koristeći metodu najmanjih kvadrata. Posebno su stavljali naglasak na stabilnost vlade, unutarnje i vanjske sukobe, korupciju, etničke napetosti, zakon i red i demokratsku odgovornost kao vrlo važne odrednice izravnih stranih ulaganja, dok rizik izvlaštenja pokazuje značajan učinak samo u njihovoj panel metodi. Nekoliko istraživanja ispituju učinak korupcije na izravna strana ulaganja i pronalaze dokaze o negativnom utjecaju na izravna strana ulaganja, (Wei 2000; Habib i Zurawicki 2002; Mathur i Sing 2013; Asideu 2006). Neovisni učinak političke stabilnosti i birokratske kvalitete također su privukli pažnju, a empirijski dokazi u velikoj mjeri sugeriraju da politička nestabilnost nema značajnog utjecaja na izravna strana ulaganja (Asideu 2002). U tablici 1 je navedeno nekoliko ključnih studija koje posebno navode razlike između istraživanja u ovisnosti od odabrane zavisne varijable, uzorka zemalja i vremenskog razdoblja.

Tablica 1: Pregled empirijske literature o pojedinim aspektima institucionalne kvalitete

Literatura	Uzorak	Varijable	Rezultat	Zavisna varijabla
Ali et. al. (2010)	69 zemalja u razvoju (1981.-2005.)	Zbroj rizika izvlaštenja i vladavina zakona kao indeksa kvalitete institucija (ICRG)	Indeks institucionalne kvalitete (rizik izvlaštenja i vladavina zakona) su signifikantne determinante FDI.	Neto FDI/BDP
Adam i Filippaios (2007)	105 razvijenih zemalja (1989.-1997.)	Politička prava i građanska sloboda, rizik izvlaštenja, korupcija i kvaliteta birokracije.	Rizik izvlaštenja je signifikantna determinanta u većini slučajeva	FDI/BDP
Addison i Heshmati (2003)	110 zemalja u razvoju (1970.-1999.)	Demokracija	Demokracija povećava FDI	Neto FDI/BDP
Asideu (2002)	71 zemlja u razvoju (1988.-1997.)	Politička nestabilnost	Politička nestabilnost nema signifikantan utjecaj na povećanje FDI	Neto FDI/BDP
Asiden (2006)	22 afričke zemlje (1984.- 2000.)	Korupcija, vladavina zakona (ICRG) i politički rizik	Korupcija smanjuje priljev FDI, dok politička stabilnost povećava FDI	Neto FDI/BDP

Izvor: izrada autora prema Akhtaruzzaman M. (2019), „International Capital Flows and the Lucas Pradox“

Jedna od glavnih rasprava mnogih istraživanja je koju vrstu stranih direktnih investicija odabrati tj. neto strane direktne investicije ili bruto strane direktne investicije. U analizama se postavlja pitanje koji način od navedena dva je bolje koristiti kao zavisnu varijablu pri analizi učinka političkog rizika (npr. efekta izvlaštenja) na strane direktne investicije. Iz standardne neoklasične teorije rasta moglo bi se potvrditi da je neto FDI (neto protok stranog kapitala u zemlju domaćina) u konačnici bolji. Međutim, može se tvrditi i da je bruto priljev stranih direktnih investicija zanimljiviji za definiranje rasta i razvoja zemlje jer FDI često uključuje transfer tehnologije i znanja koji rezultira pozitivnim priljevima u zemlji domaćin bez obzira koliko zemlja domaćin ima ulaganja u druge zemlje. Ukoliko postoje različita objašnjenja institucionalne kvalitete u odnosu na priljeve i odljeve kapitala, ima smisla i svaki tok modelirati različitim empirijskim modelima. Prema Globermanu i Shapiru (2002), ako se uzme stajalište da je neto priljev stranih direktnih investicija zavisna varijabla, može se puno toga saznati proučavanjem učinka institucionalne kvalitete na svaki od dva bruto kretanja kapitala. Istraživanjem se pokazalo da, isključujući poseban slučaj u kojem priljev i negativni odljev FDI linearno i identično reagiraju na svaku od varijabli političkog rizika, svaki pokušaj procjene njihovih učinaka na neto strane direktne investicije korištenjem modela linearne regresije rezultira pristranim procjenama. Uz ekonometrijske prednosti korištenja različitih empirijskih modela bruto priljeva i bruto odljeva, ekonomska teorija također podržava istraživanje determinanti bruto priljeva umjesto neto tokova kao zavisne varijable od primarnog interesa. Bez obzira na to u kojoj se mjeri tvrtke u razvoju odluče ulagati u inozemne projekte, izravna strana ulaganja i dalje su korisna za daljnji gospodarski razvoj poboljšavajući pristup radnika intelektualnom vlasništvu i fizičkom kapitalu. Priljev stranih direktnih investicija također ostaje važan za prelijevanje znanja i ekonomiju razmjera koji su važni u smislu rasta i razvoja iz čega se može zaključiti da su bruto strane direktne investicije relevantnije prilikom procjena. Kada se procjenjuju odrednice priljeva kapitala koristeći podatke među zemljama, bitno je kontrolirati veličinu zemlje tako što će se uključiti mjera agregatne ekonomske aktivnosti ili stanovništva ili oboje. Ključno je pitanje hoće li povećanje indeksa političkog rizika od jedne jedinice ili postotnih bodova imati slične učinke na vrijednost priljeva FDI u sve zemlje bez obzira na veličinu. Iako je ovo u konačnici empirijsko pitanje, opravdano je očekivati da predviđeni učinci priljeva kapitala na određenu promjenu u profilu institucionalne kvalitete zemlje ovise i o ukupnoj veličini gospodarstva. Neke studije jednostavno normaliziraju zavisnu varijablu bilo nacionalnim dohotkom ili brojem stanovništva u svakoj zemlji i godini. Ovaj pristup je relativno čest u empirijskoj FDI literaturi gdje su neto ili bruto FDI izraženi kao udio u BDP-u ili BNP-u. Hoće li se strane

direktne investicije normalizirati ukupnom ekonomskom aktivnošću ili stanovništvom ovisi o teorijskim vezama koje se istražuju i postavljenim pitanjima. Točnije, ako je istraživačko pitanje utvrđivanje relativne važnosti institucionalne kvalitete na strana ulaganja izražena kao udio u BDP-u, možda će biti teško razložiti relativne učinke institucionalne kvalitete na strane direktne investicije jer je institucionalna kvaliteta također izravno povezana s ekonomskom aktivnošću tj. BDP-om. Asideu (2002. 2006) i Asideu et.al. (2009), koristili su strane direktne investicije u BDP-u kao zavisnu varijablu, a Globerman i Shapiro (2002) odbili su ovu specifikaciju jer je zavisna varijabla obično bila grupirana u uskom rasponu varijacija što je proizvelo nepouzdane procjene parametara.

Prema Hacker (2007), istraživao je utjecaj stranih direktnih investicija na ekonomski rast u Kini za period 1994.- 2003. godine. Istraživanje je pokazalo da FDI ima pozitivan utjecaj na ekonomski rast koji se promatrao kroz prijenos tehnologije iz jedne zemlje u drugu i zbog toga povećala output i BDP u pojedinim zemljama. Istraživanje je provedeno za 30 različitih regija u Kini. Empirijski rezultati su pokazali pozitivan, ali nesignifikantan utjecaj FDI koji je prikazan kao udio u BDP-u. Međutim, kada su se regije koje nisu imale podatke za FDI isključile iz regresije, rezultati su pokazivali pozitivan i signifikantan utjecaj FDI na razinu BDP-a i u konačnici na ekonomski rast.

3. ANALIZA INSTITUCIONALNIH FAKTORA- EMPIRIJSKO ISTRAŽIVANJE

3.1. Podaci i metodologija

U ovom diplomskom radu će se koristiti podaci sa službene stranice Svjetske banke sa koje su prikupljeni podaci o stranim direktnim investicijama (engl. FDI) i podaci o svjetskim pokazateljima upravljanja (engl. The World Government Indicator - WGI). Kao što je ranije navedeno odabrana su tri važnija pokazatelja koja objašnjavaju kvalitetu institucija, a to su regulatorna kvaliteta, vladavina zakona i kontrola korupcije. Rad će se usmjeriti na kretanje FDI jer FDI u globalnoj ekonomiji ne predstavlja samo kretanje kapitala nego i transfer tehnologije i znanja, te na taj način doprinosi rastu konkurentnosti, zaposlenosti i međunarodne ekonomije što u konačnici dovodi do ekonomskog rasta i razvoja lokalnog gospodarstva.

Tijekom protekla dva desetljeća sve je veća integracija između tržišnih gospodarstava u nastajanju i međunarodnog tržišta. U 1980.-im i početkom 1990.-ih je neto priljev privatnog kapitala u zemljama u razvoju bio relativno nizak, ali je početkom 1990.-ih počeo rasti. Na to su utjecali promjena profitabilnosti ulaganja, smanjenje investicijskog rizika kao i promjena vanjskog okruženja. Od ranih 1980.-ih godina kapital je prema tržištima u nastajanju tekao prvenstveno u obliku stranih direktnih investicija. To je rezultiralo iz činjenice da su se strana direktna ulaganja smatrala sigurnim izvorom vanjskog financiranja. Međutim, usporedno s razvojem lokalnih financijskih tržišta u tržištima u nastajanju i njihovoj većoj otvorenosti prema stranim ulagačima, dolazi i do većeg udjela stranog portfeljnog kapitala (engl. FPI). Povećan priljev FPI je povezan s rastućim značajem institucionalnih ulagača (osiguravajuća društva, mirovinski fondovi, uzajamni fondovi, hedge fondovi, privatni fondovi itd). Pitanje koje se postavlja je treba li se u suvremenom globaliziranom svijetu FDI i PFI tretirati kao komponente zajedničke investicijske strategije ili dva odvojena načina stranog kapitala. Strane direktne investicije se događaju kada određeni ulagač (nerezident) dođe u posjed 10% ili više vlasničkog udjela gospodarskog subjekta (rezidenta), dok je strano portfeljno ulaganje skupina imovine kao što su dionice, obveznice i novčani ekvivalenti, (Humanicki et. al. 2013). Glavne razlike između FDI i PFI su vidljive na slici 5.

Slika 5: Razlika između FDI i PFI

FDI	PFI
• Aktivno ulaganje	• Pasivno ulaganje
• Direktno ulaganje	• Indirektno ulaganje
• Dugoročni kapital	• Kratkotrajni kapital
• Investiranje u financijsku i nefinancijsku imovinu	• Investiranje samo u financijsku imovinu
• Stabilne investicije	• Volatilne investicije
• Postojanje ulaznih i izlaznih barijera	• Slabo postojanje ulaznih i izlaznih barijera

Izvor: izrada autora, https://www.indiainfoline.com/article/general-blog/key-differences-between-fdi-and-fpi-119081600015_1.html

U ekonomskoj literaturi koja proučava strane direktne investicije, ispituje se veliki broj varijabli kako bi se utvrdio njihov utjecaj i povezanost s priljevom kapitala. Međutim, u svrhu pisanja ovoga rada odabrane su tri makroekonomske determinante koje utječu na priljev stranih direktnih investicija, a to su: rast BDP-a po glavi stanovnika, trgovinska otvorenost i realna kamatna stopa (prilagođena inflaciji mjerena deflatorom BDP-a). BDP po glavi stanovnika je najpoznatiji pokazatelj razvijenosti neke zemlje te postoji pozitivna veza između BDP po glavi stanovnika i privlačenja stranih direktnih investicija, zemlja koja se smatra trgovinski otvorenom također će utjecati na privlačenje stranih direktnih investicija (Wash i Yu, 2010). Podaci za BDP po glavi stanovnika i realna kamatna stopa su također preuzeti sa službene stranice Svjetske banke dok su podaci o trgovinskoj otvorenosti preuzeti sa službene stranice Our Wold In Data.

Prilikom preuzimanja podataka ustanovljeno je da za pojedine zemlje nisu dostupni svi podaci te se stoga istraživanje provelo za period od 2002. do 2017. godine na uzorku od 98 zemalja.

Indeks lakoće poslovanja indeks je kojeg su zajednički kreirali Simeon Djankov i Gerhard Pohl, dva vodeća ekonomista u Svjetskoj banci za Centralnu i Istočnu Europu. Viša pozicija u poretku tj. niža vrijednost indeksa ukazuje na bolje, obično jednostavnije propise za tvrtke i snažniju zaštitu vlasničkih prava. Istraživanja koja financira Svjetska banka, pokazuju da je snažan učinak poboljšanja ovih propisa na gospodarski rast. Izvješće Doing business je referentna studija čija se istraživanja sastoje od upitnika kojeg je izradio tim za projekt Doing business uz pomoć savjetnika. Upitnik je usredotočen na jednostavan poslovni slučaj koji osigurava usporedivost između ekonomija tijekom vremena. Istraživanje se također temelji na

pretpostavkama na pravnom obliku poduzeća, veličini, mjestu i prirodi njegovog poslovanja. Indeks lakoće poslovanja (engl. ease of doing business) namijenjen je mjerenju propisa koji izravno utječu na poduzeća i ne mjeri izravno uvjete poput blizine države, veličine tržišta, kvalitete infrastrukture, inflacije ili kriminala. Podaci iz ankete podvrgavaju se nekoliko krugova provjere, a rezultati se tumače i provjeravaju prije nego se uključe u izvješće. Poredak zemalja je baziran na prosjeku od 10 podindeksa: početak poslovanja, bavljenje građevinskim dozvolama, dobivanje struje, upis imovine, dobivanje kredita, zaštita investitora, plaćanje poreza, prekogranično trgovanje, provođenje ugovora, rješavanje nesolventnosti. Indeks lakoće poslovanja kreće se od 1 do 190. Poredak ekonomija određuje se sortiranjem ukupne lakoće poslovanja. Indeks lakoće poslovanja je jednostavan prosjek ocjena za svaku od tema Doing business koji su ranije navedeni. Rezultati se izračunavaju na temelju metodologija DB10-14, DB15-16, DB17-20. Za pojedine zemlje je došlo do preklapanja rezultata u 2014. godini tj. poklapala se metodologija DB10-14 i DB15-16, te je za potrebe ovog istraživanja odabrana metodologija DB15-16. Promjena metodologije u 2014. godini je zbog toga što su se dva pokazatelja (prekogranično trgovanje i plaćanje poreza) ažurirali.

U svrhu ovog istraživanja koristio se indeks lakoće poslovanja (engl. ease of doing business) za period 2010.-2017. godine na uzorku od 94 zemlje.

Za potrebe istraživanja određena je zavisna varijabla i veći broj nezavisnih varijabli:

- Zavisna varijabla su strane direktne investicije koje su prikazane u relativnom iznosu kao postotak BDP-a.
- Nezavisne varijable su sukladno ciljevima istraživanja i postavljenim hipotezama podijeljene u dvije skupine, makroekonomske varijable i institucionalne varijable. U regresijskoj analizi izabrano je ukupno sedam nezavisnih varijabli i to: makroekonomske (BDP po glavi stanovnika, trgovinska otvorenost koja je također mjerena u relativnom iznosu kao postotak BDP-a, inflacija,relativna kamatna stopa i stopa rasta BDP-a) i institucionalne varijable (regulatorna kvaliteta, vladavina zakona, kontrola korupcije i indeks lakoće poslovanja).

Prije nego što se provede analiza na odabranim podacima, postavljena su određena očekivanja makroekonomskih nezavisnih varijabli na zavisnu varijablu (FDI%GDP). Na temelju dosadašnje literature došlo se do sljedećih zaključaka:

- BDP po glavi stanovnika- najpoznatiji pokazatelj razvijenosti neke zemlje te se očekuje pozitivna veza sa FDI
- Trgovinska otvorenost/BDP- smatra se da što je država otvorenija privući će i više stranih ulaganja
- Realna kamatna stopa- vrijednost nominalne kamatne stope umanjena za inflaciju
- Stopa rasta BDP-a- očekuje se pozitivan utjecaj stope rasta BDP-a na inozemna ulaganja

Istraživanje je izvršeno regresijskom analizom čija je zadaća pronaći vezu između jedne zavisne i jedne ili više nezavisnih varijabli. Budući da su u ovom istraživanju korištene jedna zavisna i više nezavisnih, korištena je metoda višestruke regresije. Općeniti oblik modela je:

$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_k x_k$. Parametar β_0 je konstantni član tj. očekivana vrijednost zavisne varijable kada su sve nezavisne varijable jednake nuli. Regresijski koeficijent $\beta_j$pokazuje prosječnu promjenu zavisne varijable kada nezavisna varijabla poraste za jednu jedinicu uz uvjet da su sve ostale nezavisne varijable nepromijenjene. Za testiranje postavljenih hipoteza kreirana su dva modela višestruke regresije. Hipoteza H.1.1. testirat će se kombinacijama sljedećeg modela:

(1) FDI(%GDP)= β_0 + β_1RK+$\beta_2 VZ$+$\beta_3 KK$+$\beta_4\, GDP/capita$+β_5TO/GDP+β_6RKS+β_7SRBDP

FDI (%GDP) - relativna vrijednost stranih direktnih investicija

RK – regulatorna kvaliteta

VZ – vladavina zakona

KK – kontrola korupcije

GDP/capita – BDP po glavi stanovnika

TO/GDP – trgovinska otvorenost podijeljena sa BDP-om

RKS – relativna kamatna stop

SRBDP- stopa rasta BDP-a

Hipoteza H.1.2. testirat će se sljedećim modelom:

(2) FDI(%GDP)= β_0 +$\beta_1\, GDP/capita$+β_2TO/GDP+β_3RKS+β_4 EODB+β_5SRBDP

EODB- indeks lakoće poslovanja (engl. ease of doing business)

3.2. Rezultati istraživanja

Navedeni modeli postavljeni su na osnovu pregleda dosadašnjih istraživanja i definiranja zavisnih i nezavisnih varijabli te su se pravile različite kombinacije determinanti i na osnovu toga se prihvatio model 1. Promatrajući model u kojem se pojavljuje visoka korelacije između pojedinih varijabli, potrebno je modificirati model kako bi rezultati bili pouzdaniji. Visoka korelacija zastupljena je između varijabli regulatorna kvaliteta, vladavina zakona i kontrola korupcije. Tablica sa visokim korelacijama između pojedinih varijabli vidljiva je u **prilogu 1.** Zbog utvrđene visoke korelacije između pojedinih varijabli, iz modela je potrebno isključiti varijable koje koreliraju te ispitati zasebni utjecaj regulatorne kvalitete, vladavine zakona i kontrole korupcije na zavisnu varijablu.

Promatrajući model koji uključuje regulatornu kvalitetu, GDP/capita, trgovinsku otvorenost/GDP, realnu kamatnu stopu i stopu rasta BDP-a uočava se da prema koeficijentu determinacije (R^2) iznosi 17,4% i prilagođeni koeficijent determinacije ($\overline{R^2}$) iznosi 2,6% te prema tome model nije reprezentativan i pouzdan (**tablica 2).**

Tablica 2: Model summary – regulatorna kvaliteta

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,174[a]	,030	,026	22,881931459411817

a. Predictors: (Constant), Stopa rasta BDP-a, Trgovinska otvorenost/GDP, Regulatorna kvalitea, Realna kamatna stopa, GDP/capita

b. Dependent Variable: FDI(%GDP)

Izvor: izrada autora

Iz **tablice 3** promatrajući F pokazatelj i α koja je manja od 5% čime se zapravo i prihvaća signifikantnost modela, promatrani model je statistički značajan.

Tablica 3: ANOVA- regulatorna kvaliteta

ANOVA[a]						
Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	16919,583	5	3383,917	6,463	,000[b]
	Residual	542431,768	1036	523,583		
	Total	559351,351	1041			
a. Dependent Variable: FDI (%GDP)						
b. Predictors: (Constant), Stopa rasta BDP-a, Trgovinska otvorenost/GDP, Regulatorna kvalitea, Realna kamatna stopa, GDP/capita						

Izvor: izrada autora

U **tablici 4** prikazani su rezultati višestruke regresije tj. utjecaja regulatorne kvalitete, GDP/capita, trgovinske otvorenosti/GDP, realne kamatne stope i stope rasta BDP-a na FDI. Izraz konačnog modela je: FDI= 5,411+4,103RK+ 0,501GDP/capita-8,455TO/GDP-0,064RKS-0,233SRBDP-a. Nezavisni parametar β_0 iznos 5,411 i predstavlja očekivani priljev stranih direktnih investicija u slučaju da su sve nezavisne varijable poprimile vrijednost nula. Parametar uz nezavisnu varijablu RK tj. β_1 iznosi 4,103 i pokazuje da se može očekivati rast stranih direktnih investicija za 4,103 ukoliko se regulatorna kvaliteta poveća za 1. Parametar uz nezavisnu varijablu GDP/capita tj. uz β_2 iznosi 0,501 i pokazuje da se može očekivati rast stranih direktnih investicija za 0,501 ukoliko se GDP/capita poveća za 1.

Tablica 4: Koeficijenti - regulatorna kvaliteta

Coefficients[a]						
		Unstandardized Coefficients		Standardized Coefficients		
Model		B	Std. Error	Beta	t	Sig.
1	(Constant)	5,411	1,109		4,879	,000
	Regulatorna kvaliteta	4,103	,777	,166	5,283	,000
	GDP/capita	,501	,194	,102	2,580	,010
	Trgovinska otvorenost/GDP	-8,455	321,370	-,001	-,026	,979
	Realna kamatna stopa	-,064	,080	-,025	-,796	,426
	Stopa rasta BDP-a	-,233	,185	-,049	-1,261	,208
a. Dependent Variable: FDI (%GDP)						

Izvor: izrada autora

U **tablici 5** prikazani su rezultati model summary za model u kojem su kao nezavisne varijable uključene vladavina zakona, GDP/capita, trgovinska otvorenost/GDP, realna kamatna stopa i stopa rasta BDP-a. Iz tablice je moguće uočiti da model nije reprezentativan i pouzdan jer koeficijent determinacije (R^2) iznosi 3,7%, a korigirani koeficijent determinacije ($\overline{R^2}$) iznosi 3,2%. **Tablica 6** prikazuje ANOVA tablicu u kojoj se jasno vidi da je model statistički značajan pri razini signifikantnosti od 5%.

Tablica 5: Model summary - vladavina zakona

Model Summary				
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,192[a]	,037	,032	22,803508260465748
a. Predictors: (Constant), Stopa rasta BDP-a, Trgovinska otvorenost/GDP, Vladavina zakona, Realna kamatna stopa, GDP/capita				

Izvor: izrada autora

Tablica 6: ANOVA - vladavina zakona

ANOVA[a]						
Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	20631,362	5	4126,272	7,935	,000[b]
	Residual	538719,989	1036	520,000		
	Total	559351,351	1041			
a. Dependent Variable: FDI (%GDP)						
b. Predictors: (Constant), Stopa rasta BDP-a, Trgovinska otvorenost/GDP, Vladavina zakona, Realna kamatna stopa, GDP/capita						

Izvor: izrada autora

Tablica 7 prikazuje rezultate regresijske analize u kojoj kao nezavisne varijable ulaze regulatorna kvaliteta, GDP/capita, trgovinska otvorenost/GDP, realna kamatna stopa i stopa rasta BDP-a. Konačni izraz modela je: FDI= 5,846+ 4,419VZ+ 0,573GDP/capita+ 4,512TO/GDP- 0,033RKS- 0,280SRBDP-a. Nezavisni parametar β_0 iznosi 5,846 i predstavlja očekivati priljev stranih direktnih investicija u slučaju da su sve nezavisne varijable poprimile vrijednost nula. Parametar uz nezavisnu varijablu β_1 iznosi 4,419 i predstavlja očekivani priljev stranih direktnih investicija ukoliko dođe do porasta vladavine

zakona za 1. Parametar uz nezavisnu varijablu β_2 iznosi 0,573 i prikazuje da se možeočekivati priljev stranih direktnih investicija za 0,573 ukoliko dođe do rasta GDP/capita za 1.

Tablica 7: Koeficijenti - vladavina zakona

Coefficients[a]						
Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	5,846	1,075		5,440	,000
	Vladavina zakona	4,419	,744	,188	5,936	,000
	GDP/capita	,573	,195	,116	2,936	,003
	Trgovinska otvorenost/GDP	46,512	320,601	,004	,145	,885
	Realna kamatna stopa	-,033	,080	-,013	-,417	,677
	Stopa rasta BDP-a	-,280	,184	-,059	-1,518	,129
a. Dependent Variable: FDI (%GDP)						

Izvor: izrada autora

Iz **tablice 8** prikazani su rezultati u kojem su nezavisne varijable kontrola korupcije, GDP/capita, trgovinska otvorenost/GDO, realna kamatna stopa i stopa rasta BDP-a. Prema dobivenim rezultatima vidljivo je da nije pouzdan i reprezentativan jer je koeficijent determinacije (R^2) je 2,3%, a korigirani koeficijent determinacije ($\overline{R^2}$) 1,8%. Iz ANOVA tablice **(tablice 9)** može se zaključiti da je model statistički značajan na razini signifikantnosti od 5%.

Tablica 8: Model summary - kontrola korupcije

Model Summary				
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,150[a]	,023	,018	22,971875713959350
a. Predictors: (Constant), Stopa rasta BDP-a, Trgovinska otvorenost/GDP, Kontrola korupcije, Realna kamatna stopa, GDP/capita				

Izvor: izrada autora

Tablica 9: ANOVA - kontrola korupcije

ANOVA[a]						
Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	12646,823	5	2529,365	4,793	,000[b]
	Residual	546704,528	1036	527,707		
	Total	559351,351	1041			
a. Dependent Variable: FDI (%GDP)						
b. Predictors: (Constant), Stopa rasta BDP-a, Trgovinska otvorenost/GDP, Kontrola korupcije, Realna kamatna stopa, GDP/capita						

Izvor: izrada autora

Tablica 10 prikazuje rezultate regresijske analize u kojem su nezavisne varijable kontrola korupcije, GDP/capita, trgovinska otvorenost/GDP, realna kamatna stopa i stopa rasta BDP-a. Konačni oblik modela glasi: FDI=6,334+ 3,103KK + 0,514GDP/capita + 20,786TO/GDP – 0,048RKS – 0,296SRBDP-a. Koeficijent β_0 iznosi 6,334 i predstavlja očekivani priljev stranih direktnih investicija ukoliku su sve nezevisne varijable 0. Koeficijent β_1 iznosi 3,103 i predstavlja očekivani priljev stranih direktnih investicija od 3,103 ukoliko se kontrola korupcije poveća za 1 i koeficijent β_2 koji iznosi 0,514 te se očekuje priljev stranih direktnih investicija za 0,514 ukoliko se GDP/capita poveća za 1.

Tablica 10: Koeficijenti - kontrola korupcije

Coefficients[a]						
		Unstandardized Coefficients		Standardized Coefficients		
Model		B	Std. Error	Beta	t	Sig.
1	(Constant)	6,334	1,077		5,884	,000
	Kontrola korupcije	3,103	,701	,140	4,426	,000
	GDP/capita	,514	,196	,104	2,617	,009
	Trgovinska otvorenost/GDP	20,786	322,960	,002	,064	,949
	Realna kamatna stopa	-,048	,081	-,019	-,597	,551
	Stopa rasta BDP-a	-,296	,186	-,062	-1,591	,112
a. Dependent Variable: FDI (%GDP)						

Izvor: izrada autora

Prema rezultatima Pearsonovog koeficijenta koji je vidljiv u **prilogu 2,** može se vidjeti da ne postoji problem visoke korelacije između varijabli kod testiranja drugog modela, stoga u

analizu drugog modela ulaze sve nezavisne varijable (GDP/capita, trgovinska otvorenost/GDP, realna kamatna stopa i stopa rasta BDP-a) te se ispituje njihov utjecaj na nezavisnu varijablu strane direktne investicije.

U **tablici 11** prikazan je model summary iz kojeg se može zaključiti da model nije pouzdan i reprezentativan jer je koeficijent determinacije (R^2) 9,8%, a korigirani koeficijent determinacije ($\overline{R^2}$) 8,8%. Iz ANOVA tablice **(tablice 12)** vidljivo je da je model statistički značajan na razini signifikantnosti od 5%.

Tablica 11: Model summary- ease of doing business

Model Summary				
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,313[a]	,098	,088	7,052777657573311
a. Predictors: (Constant), Stopa rasta BDP-a, Realna kamatna stopa, Trgovinska otvorenost/GDP, Ease ob doing business, GDP/capita				

Izvor: izrada autora

Tablica 12: ANOVA- ease of doing business

ANOVA[a]						
Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	2477,321	5	495,464	9,961	,000[b]
	Residual	22831,428	459	49,742		
	Total	25308,749	464			
a. Dependent Variable: FDI (%GDP)						
b. Predictors: (Constant), Stopa rasta BDP-a, Realna kamatna stopa, Trgovinska otvorenost/GDP, Ease ob doing business, GDP/capita						

Izvor: izrada autora

Tablica 13 prikazuje rezultate regresijske analize u kojoj su nezavisne varijable GDP/capita, trgovinska otvorenost/GDP, realna kamatna stopa, stopa rasta BDP-a i ease of doing business te zavisna varijabla priljev stranih direktnih investicija. Prema rezultatima regresije model se može zapisati na sljedeći način: FDI= -8,933 + 0,150GDP/capita +258,072TO/GDP – 0,027RKS + 0,204EODB + 0,034SRBDP-a. Slobodni koeficijent β_0 iznosi -8,933 te se očekuje pad stranih direktnih investicija ukoliko su sve ostale varijable nula. Koeficijent uz

nezavisnu varijablu ease of doing business β_5 iznosi 0,034 te se očekuje priljev stranih direktnih investicija za 0,034 ukoliko se ease of doing business poveća za 1.

Tablica 13: Koeficijenti - ease of doing business

Coefficients[a]						
Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	-8,933	2,117		-4,219	,000
	GDP/capita	,150	,117	,066	1,277	,202
	Trgovinska otvorenost/GDP	258,072	222,994	,052	1,157	,248
	Realna kamatna stopa	-,027	,041	-,030	-,667	,505
	Ease ob doing business	,204	,030	,304	6,696	,000
	Stopa rasta BDP-a	,034	,113	,016	,298	,765
a. Dependent Variable: FDI (%GDP)						

Izvor: izrada autora

Na temelju dobivenih rezultata mogu se donijeti konačni zaključci. Prilikom testiranja prvog modela utvrdio se problem multikolinearnosti te su zbog toga varijable koje koreliraju izbačene iz analize i nakon toga se ispituje utjecaj zasebnih nezavisnih varijabli institucionalne kvalitete na zavisnu varijablu FDI. Nakon izvršene zasebne regresijske analize došlo se do zaključka da regulatorna kvaliteta, vladavina zakona, kontrola korupcije i GDP/capita imaju utjecaj na priljev stranih direktnih investicija.

Prilikom testiranja drugog modela nije uočen model multikolinearnosti te stoga model nije bilo potrebno modificirati. Indeks lakoće poslovanja se pokazao statistički značajnim te postoji utjecaj indeksa lakoće poslovanja na priljev stranih direktnih investicija.

3.3. Osvrt na hipoteze

Na temelju promatranih analiza i dobivenih rezultata za razdoblje od 2002. do 2017. godine hipoteza ***H.1.1. koja glasi da regulatorna kvaliteta, vladavina zakona i kontrola korupcije djeluju na kvalitetu institucija i priljev kapitala se prihvaća***. Nakon što se uvidom u tablicu Pearsonovog koeficijenta pronašla korelacija između institucionalnih varijabli, modificiranjem se zasebno radila regresijska analiza za pojedine varijable i dala pozitivne

rezultate. Naime, regulatorna kvaliteta pozitivno utječe na priljev stranih direktnih investicija i to u ovom slučaju u iznosu od 4,103 što znači da se očekuje rast stranih direktnih investicija ukoliko se regulatorna kvaliteta poveća za 1 .Vladavina zakona za vrijednosti od 4,419 također pozitivno utječe na priljev stranih direktnih investicija. Očekuje se rast stranih direktnih investicija za 4,419 ukoliko dođe do rasta vladavine zakona za 1. Kontrola korupcije također pozitivno djeluje na rast stranih direktnih investicija. Očekuje se njihov rast za 3,103 ukoliko se kontrola korupcije poveća za jedan. U svakoj regresijskoj analizi se pokazalo da GDP/capita također djeluje na priljev stranih direktnih investicije. U ovisnosti od modela rezultati su bili drukčiji, ali su svakako bili pozitivni te se očekuje rast stranih direktnih investicija ako se GDP/capita u svakom modelu poveća za 1.

Hipoteza ***H.1.2. doing business indikator pozitivno djeluje na kvalitetu institucija i na povećanje priljeva kapitala*** **se** ***može prihvatiti.*** U slučaju ispitivanja hipoteze H.1.2. nije uočen problem visoke korelacije između varijabli pa je stoga u analizu uvršten cijeli model u kojem su nezavisne varijable GDP/capita, trgovinska otvorenost/GDP, realna kamatna stopa i stopa rasta BDP-a. Analizom rezultata pokazalo se da indeks lakoće poslovanja (engl. ease of doing business) kao jedan od komponenti Doing businessa pozitivno djeluje na priljev stranih direktnih investicija. Koeficijent govori da će doći do rasta stranih direktnih investicija za 0,204 ukoliko se indeks lakoće poslovanja poveća za 1. Prihvaćanje ove hipoteze na tragu je istraživanja koje su proveli Djankov, McLieshe i Ramalho (2006), koji su dokazali da postoji veza između Doing business indikatora i ekonomskog rasta.

Na osnovu prihvaćanja H.1.1. i H.1.2. hipoteze u konačnici se i hipoteza ***H.1. kvaliteta institucija je i dalje vodeća varijabla za objašnjenje Lucasovog paradoksa može prihvatiti.*** Prema osnovnim teorijskim pretpostavkama da se rješenje Lucasovog paradoks objašnjava institucionalnom kvalitetom, teorijsko stajalište i istraživanje ovog rada se podudaraju. Budući da Lucasov paradoks govori o kretanju kapitala između siromašnih i bogatih zemalja, u svrhu ovog istraživanja priljev kapitala se računao kao udio stranih direktnih investicija u BDP-u. Veći priljev stranih direktnih investicija u zemlju će u konačnici dovesti i do ekonomskog rasta zemlje.

3.4. Budućnost Lucasovog paradoksa

Prema Haldenu (2010.), Središnja banka Ujedinjenog Kraljevstva je izradila projekciju o tokovima kapitala između G20 zemalja u narednih 40 godina. Ključni rezultati su sugerirali

da bi se ukupna veličina vanjske bilance u odnosu na BDP povećala u rasponu od 1,3 do 2,2. Pretpostavlja se da će više od 40% vanjske imovine, do 2050. godine posjedovati BRIC zemlje (Brazil, Rusija, Indija i Kina), što je više od 10% koje je zabilježeno u 2010. godini. Globalne neravnoteže tekućeg računa (zbroj deficita i suficita) porasle bi s 4% svjetskog BDP-a na oko 8%. Tokovi kapitala u zemljama u razvoju naglo su se preokrenuli od 2015. godine, a neto odljevi kapitala zemalja u razvoju premašili su 600 milijardi dolara što je više od četvrtine ukupnih priljeva u zemlje u razvoju ostvarenih 2008.- 2014. godine (Stiglitz i Rashid, 2016.). Velika količina odljeva kapitala iz zemalja u razvoju imat će znatne negativne učinke na rast i razvoj zemalja u razvoju. Zemlje u razvoju mogle bi razmatrati povećanje kamatne stope kako bi privukli više kapitala. Međutim, povećanje kamatne stope može i negativno djelovati na velika poduzeća zemalja u razvoju jer veliki odljev kapitala negativno utječe na cijenu dionica, stoga je potrebno biti oprezan oko kreiranja kamatnih stopa. Monetarna ekonomija razvijenih gospodarstava, a posebno SAD-a mogla bi utjecati na tokove kapitala na tržištima gospodarstava u nastajanju.

Trgovinski rat između Kine i SAD-a i promjene u američkoj politici će vjerojatno utjecati na globalne tokove kapitala. Trgovinski rat je već promijenio kineski FDI u SAD-u. Do prve polovice 2018. godine kineski FDI smanjio se za 90% na samo 1,8 milijardi dolara (Putz et.al. 2019). Ako se ovaj trend nastavi, ulazni tokovi kapitala bit će znatno smanjeni ukoliko ne dođe do promjene napetosti između Amerike i Kine. Zbog nametnutih carina koje je SAD uvela prema Kini, Meksiku, Kanadi i EU, promjene u trgovini robom zbog novih carina će vjerojatno utjecati na trgovinu kapitalom. Tako bi se protok kapitala smanjio ne samo iz zemalja u razvoju u razvijene zemlje nego i između razvijenih zemalja. Potencijalni protekcionistički pristup SAD-a bi na kraju mogao izolirati najveće svjetsko gospodarstvo od ostatka svijeta te stvoriti novi svjetski poredak.

ZAKLJUČAK

U ovom diplomskom radu se istraživao Lucasov paradoks koji se odnosi na promatranje kretanja kapitala između bogatih i siromašnih zemalja. Neoklasična teorija tvrdi da se kapital slobodno kreće prema siromašnim zemljama, a Lucasov paradoks to odbacuje jer kaže da je taj protok daleko niži. Dosadašnjim teorijskim pristupom Lucasov paradoks se može objasniti kroz ekonomske pokazatelje (fundamente) kao što su: faktori koji nedostaju u proizvodnji, vladine politike i institucionalna struktura te kroz asimetriju informacija i rizik zemlje. Mnoga istraživanja su pokušala pronaći rješenje za Lucasov paradoks prilikom čega su jedna govorila da je institucionalna kvaliteta važna prilikom rješavanja paradoksa, a druga su govorila da institucionalna kvaliteta nije važna.

Istraživanje provedeno u ovom diplomskom radu uključivalo je 98 zemalja u svrhu testiranja hipoteze da regulatorna kvaliteta, vladavina zakona i kontrola korupcije djeluju na kvalitetu institucija za razdoblje od 2002. do 2017. godine odnosno 94 u svrhu testiranja hipoteze da doing business indikator djeluje na kvalitetu institucija i na povećanje priljeva kapitala za razdoblje od 2010. do 2017. godine. Determinante koje su uzete u istraživanje su podijeljene u dvije skupine: makroekonomske (GDP/capita, trgovinska otvorenost/GDP i realna kamatna stopa) i institucionalne (vladavina zakona, kontrola korupcije, regulatorna kvaliteta i indeks lakoće poslovanja). Pretpostavka istraživanja je da navedene varijable djeluju na priljev kapitala i u konačnici objašnjavaju Lucasov paradoksa. Otežavajuća okolnost je bila ta što su podaci o nekim varijablama bili nedostupni u bazi podataka Svjetske banke te stoga istraživanje nije u potpunosti reprezentativno. Empirijska analiza je provedena pomoću regresijske analize korištenjem programa SPSS.

Prilikom testiranja hipoteze utvrđen je problem visoke korelacije između institucionalnih varijabli (regulatorna kvaliteta, vladavina zakona i kontrola korupcije). Nakon modificiranja modela ispitao se zaseban utjecaj svake nezavisne varijable na zavisnu varijablu (strane direktne investicije). Rezultati analize su pokazali da regulatorna kvaliteta, vladavina zakona i kontrola korupcije u konačnici imaju pozitivan utjecaj na priljev stranih direktnih investicija. Ukoliko dođe do porasta jedne od ovih varijabli, doći će do rasta stranih direktnih investicija. Kada ove rezultate usporedimo sa definicijama svake varijable zasebno, ovakva pozitivna veza zapravo je i očekivana. Regulatorna kvaliteta je sposobnost vlade da formulira i provodi zdrave politike i propise koji dopuštaju i promiču razvoj privatnog sektora.

Vladavina zakona govori o tome u kojoj mjeri agenti imaju povjerenja i poštuju pravila društva, posebno kvaliteta izvršenja, ugovora, imovinskih prava, policije i sudova kao i vjerojatnosti kriminala i nasilja. Kontrola korupcije prikazuje percepciju u kojem se javna vlast koristi u privatnom sektoru. Testiranje druge hipoteze nije naišlo na problem visoke korelacije između nezavisnih varijabli, stoga su u regresijski model uvrštene sve nezavisne varijable. Konačni rezultat je pokazao da indeks lakoće poslovanja pozitivno djeluje na priljev stranih direktnih investicija. Ukoliko dođe do rasta indeksa lakoće poslovanja doći će i do rasta stranih direktnih investicija. I ovaj se rezultat također podudara s teorijskim objašnjenjem doing businessa tj. indeksa lakoće poslovanja u kojem država ako je bolje rangirana će i imati bolje poslovanje. Prilikom testiranja raznih modela ustanovilo se i da GDP/capita ima pozitivan utjecaj na priljev stranih direktnih investicija što je također opravdano jer je GDP/capita jedan od najpoznatijih pokazatelja za definiranje razvoja zemlje. Prema rezultatima analize u konačnici se prihvatilo da je kvaliteta institucija i dalje vodeća varijabla za objašnjenje Lucasovog paradoksa.

Na kraju se može utvrditi da je ovo istraživanje potvrdilo teorijske postavke i dosadašnja istraživanja u kojem je institucionalna kvaliteta vodeća za objašnjenje Lucasovog paradoksa. Međutim, kao i u svim ekonomskim procesima ništa nije tako jednostavno te konačni i najbolji rezultati su dobiveni kombiniranjem mnoštva determinanti. Stoga budućnost kapitalnih tokova i budućnost Lucasovog paradoksa ovisi će o geopolitičkom razvoju, o budućim ekonomskim velesilama i promjenama makroekonomskih varijabli kako u razvijenim tako i u zemljama u razvoju.

LITERATURA

1. Alfaro L., Kalemli- Ozcan S., Volosovych V., (2005). Why Doesn't Capital Flow From Rich to Poor Countries? An Empirical Investigation (Working Paper 11901). National Bureau of Economic Research, raspoloživo na: https://www.nber.org/papers/w11901.pdf
2. Abiad A., Leigh D. i Mody A. (2009), „Financial integration, capital mobility, and income convergence“. Econ Policy 24(58):241–305, raspoloživo na: http://www.amody.com/pdf/finance-and-convergence.pdf
3. Asiedu E, Jin Y. i Nandwa B. (2009), „Does foreign aid mitigae the adverse effect of expropriation risk on foreign direct investment“, J Int Econ 78(2):268-275, raspoloživo na: https://econpapers.repec.org/article/eeeinecon/v_3a78_3ay_3a2009_3ai_3a2_3ap_3a268-275.htm
4. Azémar C., Desbordes R., (2013), Has the Lucas paradox been fully explained?, Econ Lett 121(2):183–187
5. Benassy- Quere et.al. (2007), „institutional determinants of foreign direct investment“, World Econ 30(5):764-782, raspoloživo na: https://econpapers.repec.org/article/blaworlde/v_3a30_3ay_3a2007_3ai_3a5_3ap_3a764-782.htm
6. Bilal K., (2017), „Lucas Paradox in The Long Run“, Anadol University, raspoloživo na: https://mpra.ub.uni-muenchen.de/78126/1/MPRA_paper_78126.pdf
7. Broszkiewicz M., (2017), „Portfolio investment flows and the Lucas paradox – an evidence from the global economy in 21st century“ Ekonomia XXI Wieku, raspoloživo na: https://dbc.wroc.pl/Content/38946/PDF/Broszkiewicz_Portfolio_Investment_Flows_And_The_Lucas_2017.pdf
8. Bruinshoofd A. (2016), „Institutional quality and economic performance“ , raspoloživo na: https://economics.rabobank.com/publications/2016/january/institutional-quality-and-economic-performance/
9. Busse M. i Hefeker C. (2007), „Political risk, institutions and foreign direct investment“, Eur J Polit Econ 23(2): 397-415, raaspoloživo na: https://econpapers.repec.org/article/eeepoleco/v_3a23_3ay_3a2007_3ai_3a2_3ap_3a397-415.htm

10. Calvo, G., Leiderman L. i Reinhart C. (1996), „Inflows of Capital to Developing Countries in the 1990s," The Journal of Economic Perspetives 10, 123-139. raspoloživo na: https://pubs.aeaweb.org/doi/pdfplus/10.1257/jep.10.2.123
11. Caselli F. i Feyrer J. (2007), „The Marginal Product of Capital", Q. J. Econ 122(2): 535-568. raspoloživo na: https://personal.lse.ac.uk/casellif/papers/MPK.pdf
12. Champion, M. i von Repert- Bismarck J. (2005), „Talking Turkey Pays Dividends Mere Star EU Negotiations is Enough to Encourage Investors", Wall Street Journal, raspoloživo na: https://www.wsj.com/articles/SB112844953162359737
13. Daude C. i Stein E. (2004), „The quality of institutions and foreign direct investment", Economic and Politics. raspoloživo na: http://econweb.umd.edu/~daude/research_files/institutions.pdf
14. Djankov S., McLiesh C. i Ramalho R. (2006), „Regulation and Growth Economic" Economic Letters 92(3). 395-401, raspoloživo na: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=893321
15. Ferguson, N. (2011), „The British Empire and Globalization", raspoloživo na: http://www.originofnations.org/British_Empire/british_empire_and_globalization.htm
16. Fernandez-Arias E. (1996), „The new wave of private capital inflows: push or pull?" J Dev Econ. 48(2):389–418, raspoloživo na: https://www.sciencedirect.com/science/article/abs/pii/0304387895000410
17. Gillanders R. i Whelan K. (2010), „Open for Business? Institutions, Business Environment and Economic Development", University College Dublin , raspoloživo na: https://www.karlwhelan.com/Papers/gillanderswhelan.pdf
18. Haldane AG. (2010), „Gobal imbalances in retrospect and prospect". Bank of England. raspoloivo na: https://www.bankofengland.co.uk/-/media/boe/files/speech/2010/global-imbalances-in-retrospect-and-prospect-speech-by-andrew-haldane.pdf
19. Humanicki M., Kelm R. i Olzewski K., (2013), „Foreign Direct Investment and Foreign Portfolio Investment in the contemporary globalized world: Should they be still treated separately"? (Working Paper No. 167) NBP, raspoloživo na: https://www.nbp.pl/publikacje/materialy_i_studia/167_en.pdf
20. IIF (2015) Capital flows to emerging markets, IIF, Washington, DC
21. Islam R. i Montenegro C. (2002), „What Determines the Quality of Institutions?" (Working Paper 2764). World Development Report, raspoloživo na: http://documents1.worldbank.org/curated/en/416091468766754963/pdf/multi0page.pdf

22. Ju, Jiandgon i Wei S. (2006), „A Solution to Two Paradox of International Capital Flow“ (Working Paper 06/178). IMF Working Paper , raspoloživo na: https://www.imf.org/external/pubs/ft/wp/2006/wp06178.pdf
23. Klein M., (2005), „Capital account liberalization, institutional quality and economic growth: theory and evidence“ (Working Paper 11112), National Bureau of Economic Research, raspoloživo na: https://www.nber.org/papers/w11112.pdf
24. Lambsdorff J., (2002), „How corruption affects persistent capital flows“, Economic of Governance. raspoloživo na: http://www.icgg.org/literature/E_Gov.pdf
25. Lehne J., Mo j. i Plekhlanov A. (2014), „What determines the quality of economic institutions? Cross-country evidence“ (Working Paper No. 171), European Bank for Reconstruction and Development. raspoloživo na: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3121122
26. Lowe M., Papageorgiov C. i Perez- Sebastian F., (2012), „The Public And Private MPK“, raspoloživo na: https://ideas.repec.org/p/deg/conpap/c017_021.html
27. Lucas, Robert E. (1990), „Why doesn't Capital Flow from Rich to Poor Countries?“ American Economic Review 80, 92–96. raspoloživo na: http://econ.sciences-po.fr/sites/default/files/file/Lucas-Why-Doesn't-Capital-Flow.pdf
28. Montiel, P. (2006), „Obstacles to Investment in Africa: Explaining the Lucas Paradoxs!, raspoloživo na: https://www.imf.org/external/np/seminars/eng/2006/rppia/pdf/montie.pdf
29. Obstfeld, M. i Rogoff K., (2000), „The Six Major Puzzles in International Macroeconomics: Is There a Common Cause?“ in NBER Macroeconomics Annual 2000, Ben Bernanke and Kenneth Rogoff, editors. The MIT Press, Cambridge., raspoloživo na: https://www.journals.uchicago.edu/doi/pdfplus/10.1086/654423
30. Okada K., (2013), „The interaction effects of financial openness and institutions on international capital flows“. J Macroecon 35:131–143, raspoloživo na: https://ideas.repec.org/a/eee/jmacro/v35y2013icp131-143.html
31. Portes R. i Rey H. (2005), „The determinants of cross-border equity flows.“ J Int Econ 65(2):269–296, raspoloživo na: http://faculty.london.edu/rportes/CrossborderJIE2.pdf
32. Putz A., Mirhaydari A. i Clark K, (2019), „How Trump'S trade war with China will affect U.S. investment markets“. Seattle Business. raspoloživo na: https://www.seattlebusinessmag.com/finance/how-trumps-trade-war-china-will-affect-us-investment-markets
33. Stiglitz JE. i Rashid H., (2016), „ How can developing countries stop their capital draining away?“ World Economic Forum. raspoloživo na:

https://www.weforum.org/agenda/2016/02/how-can-developing-countries-stop-their-capital-draining-away

34. Spar, Debora (1998), „Attracting High Technology Investment: Intel's Costa Rica Plant," World Bank Occasional Paper 11. World Bank, Washington, D.C., raspoloživo na: http://documents.worldbank.org/curated/en/949541468770676701/pdf/multi0page.pdf
35. Schularick, M. (2008), „The Lucas paradox and the quality of institutions: Then and Now", raspoloživo na: https://web.archive.org/web/20110719025638/http://www.jfki.fu-berlin.de/faculty/economics/team/persons/schularick/Lucas_discussion_paper_FUB.pdf
36. The World Bank (2020), Doing Business, raspoloživo na: https://www.doingbusiness.org/
37. Wash J.P. i Yu J., (2003), „ Determinants of Foreign Direct Investment: A Sectoral and Institutional Approach", (Working Paper 10/187), IMF, raspoloživo na: https://www.imf.org/external/pubs/ft/wp/2010/wp10187.pdf
38. Wei S., i Wu Y., (2001), „Negative alchemy? Corruption, composition of capital flows, and currency crieses" (Working Paper 8187), National Bureau of Economic Research, raspoloživo na: https://www.nber.org/papers/w8187.pdf
39. Williamson, J. (2002), „Winners and losers iver Two Centuries of Globalization", raspoloživo na: https://www.nber.org/papers/w9161
40. Worldwide Governance Indicator, https://info.worldbank.org/governance/wgi/

POPIS TABLICA

Tablica 1: Pregled empirijske literature o pojedinim apsektima institucionalne kvalitete.....22

Tablica 2: Model summary- regulatorna kvaliteta.....29

Tablica 3: ANOVA- regulatorna kvaliteta.....30

Tablica 4: Koeficijenti- regulatorna kvaliteta.....30

Tablica 5: Model summary- vladavina zakona.....31

Tablica 6: ANOVA- vladavina zakona.....31

Tablica 7: Koeficijenti- vladavina zakona.....32

Tablica 8: Model summary- kontrola korupcije.....33

Tablica 9: ANOVA- kontrola korupcije.....33

Tablica 10: Koeficijenti- kontrola korupcije.....34

Tablica 11: Model summary- ease of doing business.....34

Tablica 12: ANOVA- ease of doing business.....35

Tablica 13: Koeficijenti- ease of doing business.....35

POPIS SLIKA

Slika 1: Dijagram rasipanja „naive“ MPK i unutarnjih direktnih investicija.....13

Slika 2: Dijagram rasipanja izmijenjenog MPK i unutarnjih direktnih investicija.....14

Slika 3: Deskriptivna statistika.....16

Slika 4: Metoda najmanjih kvadrata- IMF podaci.....18

Slika 5: Razlika između FDI i PFI.....25

PRILOZI

Prilog 1: Pearsonov koeficijent za hipotezu H 1.1.

		FDI (%GDP)	Regulatorna kvalitea	Vladavina zakona	Kontrola korupcije	GDP/capita	Trgovinska otvorenost/GDP	Realna kamatna stopa	Stopa rasta BDP-a
FDI (%GDP)	Pearson Correlation	1	,139**	,144**	,114**	,010	-,007	-,032	-,025
	Sig. (2-tailed)		,000	,000	,000	,701	,770	,308	,332
	N	1559	1559	1559	1559	1558	1559	1046	1554
Regulatorna kvalitea	Pearson Correlation	,139**	1	,945**	,903**	-,187**	-,092**	-,037	-,149**
	Sig. (2-tailed)	,000		,000	,000	,000	,000	,225	,000
	N	1559	1568	1568	1568	1560	1559	1048	1560
Vladavina zakona	Pearson Correlation	,144**	,945**	1	,963**	-,213**	-,120**	-,099**	-,136**
	Sig. (2-tailed)	,000	,000		,000	,000	,000	,001	,000
	N	1559	1568	1568	1568	1560	1559	1048	1560
Kontrola korupcije	Pearson Correlation	,114**	,903**	,963**	1	-,209**	-,112**	-,098**	-,110**
	Sig. (2-tailed)	,000	,000	,000		,000	,000	,002	,000
	N	1559	1568	1568	1568	1560	1559	1048	1560
GDP/capita	Pearson Correlation	,010	-,187**	-,213**	-,209**	1	,105**	-,061*	,671**
	Sig. (2-tailed)	,701	,000	,000	,000		,000	,047	,000
	N	1558	1560	1560	1560	1560	1558	1048	1556
Trgovinska otvorenost/GDP	Pearson Correlation	-,007	-,092**	-,120**	-,112**	,105**	1	,098**	,052*
	Sig. (2-tailed)	,770	,000	,000	,000	,000		,002	,039
	N	1559	1559	1559	1559	1558	1559	1046	1554
Realna kamatna stopa	Pearson Correlation	-,032	-,037	-,099**	-,098**	-,061*	,098**	1	-,112**
	Sig. (2-tailed)	,308	,225	,001	,002	,047	,002		,000
	N	1046	1048	1048	1048	1048	1046	1048	1044
Stopa rasta BDP-a	Pearson Correlation	-,025	-,149**	-,136**	-,110**	,671**	,052*	-,112**	1
	Sig. (2-tailed)	,332	,000	,000	,000	,000	,039	,000	
	N	1554	1560	1560	1560	1556	1554	1044	1560

*. Correlation is significant at the 0.05 level (2-tailed).

**. Correlation is significant at the 0.01 level (2-tailed).

Prilog 2: Pearsonov koeficijent za hipotezu H 1.2.

Correlations

		FDI (%GDP)	GDP/capita	Trgovinska otvorenost/GDP	Realna kamatna stopa	Ease ob doing business	Stopa rasta BDP-a
FDI (%GDP)	Pearson Correlation	1	-,012	-,014	-,058	,082*	-,018
	Sig. (2-tailed)		,748	,709	,191	,029	,623
	N	749	749	749	508	706	749
GDP/capita	Pearson Correlation	-,012	1	-,006	,049	,039	,638**
	Sig. (2-tailed)	,748		,877	,269	,299	,000
	N	749	749	749	508	706	749
Trgovinska otvorenost/GDP	Pearson Correlation	-,014	-,006	1	,093*	-,126**	-,036
	Sig. (2-tailed)	,709	,877		,037	,001	,319
	N	749	749	749	508	706	749
Realna kamatna stopa	Pearson Correlation	-,058	,049	,093*	1	-,135**	-,001
	Sig. (2-tailed)	,191	,269	,037		,004	,979
	N	508	508	508	508	465	508
Ease ob doing business	Pearson Correlation	,082*	,039	-,126**	-,135**	1	-,068
	Sig. (2-tailed)	,029	,299	,001	,004		,070
	N	706	706	706	465	709	706
Stopa rasta BDP-a	Pearson Correlation	-,018	,638**	-,036	-,001	-,068	1
	Sig. (2-tailed)	,623	,000	,319	,979	,070	
	N	749	749	749	508	706	749

*. Correlation is significant at the 0.05 level (2-tailed).

**. Correlation is significant at the 0.01 level (2-tailed).

Prilog 3: Deskriptivna statistika za H.1.1. hipotezu

Descriptive Statistics

	N	Range	Minimum	Maximum	Mean		Std. Deviation	Variance
	Statistic	Statistic	Statistic	Statistic	Statistic	Std. Error	Statistic	Statistic
FDI (%GDP)	1559	509,9621926	-58,3228805	451,6393122	7,111267986	,5941890977	23,46106575	550,422
Regulatorna kvalitea	1568	4,604651690	-2,34410858	2,260543108	,4277702127	,0249254478	,9869973774	,974
Vladavina zakona	1568	4,355559111	-2,25528574	2,100273371	,3160214296	,0262693228	1,040212113	1,082
Kontrola korupcije	1568	4,142866850	-1,67287612	2,469990730	,3202151655	,0276204007	1,093712069	1,196
GDP/capita	1560	85,19625349	-34,9597548	50,23649871	2,597487890	,1197182478	4,728491918	22,359
Trgovinska otvorenost/GDP	1559	,0330864716	,0000000000	,0330864716	,0003391148	,0000496978	,0019622771	,000
Realna kamatna stopa	1048	127,5120248	-33,5969466	93,91507814	5,378685730	,2761995439	8,941360361	79,948
Stopa rasta BDP-a	1560	87,25861168	-33,1008374	54,15777429	3,834835730	,1205026128	4,759471853	22,653
Valid N (listwise)	1042							

Prilog 4: Deskriptivna statistika za H.1.2. hipotezu

Descriptive Statistics

	N	Range	Minimum	Maximum	Mean		Std. Deviation	Variance
	Statistic	Statistic	Statistic	Statistic	Statistic	Std. Error	Statistic	Statistic
FDI (%GDP)	749	308,7166196	-28,5847865	280,1318331	6,359734445	,6836918405	18,71118556	350,108
GDP/capita	749	53,81257900	-29,8270690	23,98551001	2,005214973	,1266076791	3,464981789	12,006
Trgovinska otvorenost/GDP	749	,0081483049	,0000000000	,0081483049	,0002424648	,0000432633	,0011840231	,000
Realna kamatna stopa	508	85,54890874	-33,5969466	51,95196211	5,181608158	,3604054568	8,123126455	65,985
Ease ob doing business	709	57,58208000	31,12013000	88,70221000	67,04809475	,4104652536	10,92948044	119,454
Stopa rasta BDP-a	749	53,15697157	-27,9944385	25,16253305	3,154188690	,1276708555	3,494078657	12,209
Valid N (listwise)	465							

SAŽETAK

Lucasov paradoks govori o tome da kapital ne teče iz razvijenih zemalja u zemlje u razvoju unatoč tome što zemlje u razvoju imaju nisku razinu kapitala po radniku. Brojni su čimbenici koji mogu djelovati na rješavanje Lucasovog paradoksa. Rješavanje paradoksa se može promatrati kroz prizmu priljeva stranih direktnih investicija. Kvaliteta institucija je jedna od vodećih stvari za objašnjavanje paradoksa.

Temeljem provedene višestruke linearne regresije nakon uklanjanja problema visoke korelacije između varijabli te zasebne analize došlo se do zaključka da sve institucionalne varijable (regulatorna kvaliteta, vladavina zakona i kontrola korupcije) pozitivno djeluju na priljev stranih direktnih investicija. Uz njih i GDP/ capita pozitivno utječe na priljev stranih direktnih investicija što se i slaže s teorijom da je GDP/capita jedan od glavnih za objašnjenje ekonomskog rasta zemlje.

Budućnost Lucasova paradoksa uvelike ovisi o budućim velesilama, geopolitičkom razvoju te promjenama makroekonomskih varijabli zemalja u razvoju i razvijenih zemalja.

Ključne riječi: Lucasov paradoks, strane direktne investicije, makroekonomske varijable, institucionalne varijable, kvaliteta institucija

SUMMARY

Lucas paradox is observation that capital does not flow from developed countries to developing countries despite developing countries have low level of capital per worker. There are number of factors that can solve the Lucas paradox. Solving the Lucas paradox can be viewed through the prism of foreign direct investment (FDI). The quality of institutions is one of the leading things to explain the Lucas paradox.

Based on the multiple regression and after eliminating problem of high correlation between some variables (regulatory quality, rule of law and control of corruption) they have positive effect on the inflow of foreign direct investment. In addition, GDP/capita has a positive impact on the inflow of foreign direct investment which agrees with the theory that GDP/capita is one of the main reason for economic growth.

The future of the Lucas paradox largely depends of the future of the economic superpowers, geopolitical development and changes in the macroeconomic variables of developing countries.

Key words: Lucas paradox, foreign direct investment, macroeconomic variables, institutional variables, quality of institutions