Analiza štednje i determinanti štednje u izabranim članicama Europske unije

Mladinić, Vicko

Master's thesis / Diplomski rad

2018

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:124:657938

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

zir.nsk.hr

UNIVERSITY OF SPLIT

dabar

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U SPLITU

EKONOMSKI FAKULTET

DIPLOMSKI RAD

Analiza štednje i determinanti štednje u izabranim članicama Europske unije

Mentor:
Prof. dr. sc. Marijana Ćurak

Student:
Vicko Mladinić

Split, veljača 2018.

SADRŽAJ:

1. UVOD 3

1.1. Problem istraživanja 3

1.2. Predmet istraživanja 5

1.3. Istraživačke hipoteze 6

1.4. Ciljevi istraživanja 8

1.5. Metode istraživanja 9

1.6. Doprinos istraživanja 9

1.7. Struktura diplomskog rada 10

2. ŠTEDNJA 11

2.1. Teorijske osnove štednje 11

2.1.1. Teorije kamatne stope 11

2.1.2. Teorija dohotka 12

2.1.3. Neoklasična načela 14

2.2. Instrumenti štednje 14

2.2.1. Depoziti 14

2.2.2. Ulaganje u instrumente nebankovnih financijskih institucija 16

2.2.3. Ulaganje u vrijednosne papire 18

2.2.4. Ulaganje u nekretnine 20

3. DETERMINANTE ŠTEDNJE 21

3.1. Ekonomski čimbenici 21

3.1.1. Dohodak 21

3.1.2. Inflacija 22

3.1.3. Nezaposlenost 24

3.1.4. Kamatna stopa 25

3.2. Demografski čimbenici 25

3.2.1. Broj o hranitelju obitelji ovisnih članova 25

3.2.2. Urbanizacija 26

3.3. Ostali specifični čimbenici 26

3.4. Financijska kriza 28

4. ANALIZA ŠTEDNJE U IZABRANIM ČLANICAMA EU 30

5. EMPIRIJSKO ISPITIVANJE VAŽNOSTI UTJECAJA EKONOMSKIH I DEMOGRAFSKIH DETERMINANTI ŠTEDNJE 34

5.1. Podaci i metodologija 34

5.2. Rezultati istraživanja 39

5. ZAKLJUČAK 44

LITERATURA 46

PRILOG 1 53

POPIS GRAFIKONA I TABLICA 71

SAŽETAK 73

SUMMARY 73

1. UVOD

1.1. Problem istraživanja

Štednja je dio nepotrošenog dohotka, predstavljena kao razlika između dohotka i potrošnje. Oblikuje se pod utjecajem različitih determinanti, a plasman štednje ima različite oblike, ovisne o dobnoj strukturi, averziji prema riziku pojedinca, prinosima na štednju i mnogim drugim faktorima. Značajna ulaganja štednje kreirana su u obliku depozita, dionica, investicijskih fondova, životnog osiguranja, mirovinskih fondova i nekretnina.

Brojna su teorijska promišljanja i objašnjenja o determinantama štednje, a kao najznačajnija izdvajaju se teorije klasičnih ekonomista i Keynesa. Prema teoriji klasičnih ekonomista, kamatna stopa determinira obujam štednje, dok Keynes objašnjava štednju kao rastuću funkciju dohotka.

Teorija klasičnih ekonomista predstavlja *kamatnu stopu* kao faktor koji uravnotežuje potražnju i ponudu štednje, tj. kao točku u kojoj je obujam investicija (potražnja za štednjom) jednak iznosu ponude štednje. Kroz teoriju stvarne kamatne stope ističu Bohm Bawerk-ovu *„vremensku prednost“* koja naglašava sklonost pojedinca prema tekućim dobrima u odnosu na buduća dobra. Tvrdnja proizlazi iz promišljanja vremenskog opadanja vrijednosti dobara, a *kamatna stopa* predstavlja ključnu ulogu nadoknade padajuće korisnosti. U tom slučaju, pojedinac prihvaća štednju ukoliko će korisnost buduće potrošnje biti jednaka ili veća od korisnosti tekuće potrošnje.

S druge strane, nasuprot mišljenju klasičnih ekonomista, Keynes (1936) razvija *hipotezu apsolutnog dohotka*, te zagovara tvrdnju da veličina *dohotka* određuje štednju, Temeljno razilaženje mišljenja u odnosu na klasične ekonomiste je teorija *sklonost potrošnji,* potrošač određuje dio dohotka koji odvaja za potrošnju, a štednja predstavlja nepotrošeni dio. Osnovna Keynesova tvrdnja podrazumijeva da rast dohotka ne uzrokuje proporcionalan rast potrošnje, već se povećava proporcija štednje.

Keynes promatra kamatnu stopu kao nagradu odricanja od likvidnosti, olakšavajući pojedincu izbor instrumenta ulaganja novca što predstavlja suprotnost mišljenju pripadnika klasične teorije.

Istraživanjem determinanti štednje nakon Keynes-ovih doprinosa teorijom apsolutnog dohotka, razvijaju se nove hipoteze, od kojih se izdvajaju *teorije relativnog i permanentnog dohotka*, te *hipoteza o „životnom ciklusu“*.

Pojatina (2000) i Babić (2007) ističu Duesenberry-vu (1967) *hipotezu relativnog dohotka* koji naglašava *„demonstracije“* i *„ugledanja“* kao uzrok povećane potrošnje i bez povećanja dohotka, odnosno potrošnja ovisi o odnosu dohotka pojedinca i dohotku njegovih susjeda, a ne o apsolutnoj razini dohotka. U slučaju smanjenog ili nepromijenjenog dohotka u odnosu na kategoriju ljudi kojoj pripada pojedinac, smanjuje se relativni položaj, životni standard pojedinca. Da bi sačuvao životni standard, pojedinac povećava udio potrošnje na štetu štednje.

Temeljna razlika u odnosu prve dvije teorije i *teorije permanentnog dohotka*, naglašena je u egzogenoj varijabli, pri čemu se koristi permanentni dohodak, umjesto tekućeg dohotka. Nadalje, Friedman (1957) dijeli dohodak i potrošnju na permanentni i tranzitorni dio. Dok permanentni dohodak kao procjena budućih prihoda utječe na potrošnju, stav autora o tranzitornom dohotku, kao posljedici slučajnih faktora, je da u kratkom roku ima utjecaj na štednju, a ne potrošnju.

Ando i Modigliani (1963) razvijaju *teoriju životnog ciklusa* bazirajući se na Friedman-ova teorijska promišljanja. Ova teorija naglašava da sklonost štednji ili potrošnji ovisi o životnoj dobi. Najveća razina štednje obilježena je u radno aktivnom razdoblju pojedinca, koju karakterizira trend rasta do određenog vremena nakon kojeg ostvaruje pad.

Proces donošenja odluke o štednji, te izboru optimalnog instrumenta ulaganja je složen s obzirom da se svaki pojedinac razlikuje. Pored navedenih čimbenika koji utječu na ponašanje pojedinca u potrošnji/štednji, ovisno o teoriji pogleda, ističu se i druge determinante.

Muradoglu i Taskin (1996) ispituju utjecaj ekonomskih i demografskih čimbenika na štednju. Potvrđuju razliku u važnosti i značajnosti determinanti utjecaja u usporedbi razvijenih i nerazvijenih zemalja. Naglašavaju dobnu strukturu i dohodak kao značajne varijable u razvijenim zemljama, dok rast raspoloživog dohotka, inflaciju i stope povrata navode kao važne u nerazvijenim zemljama.

Uz ekonomske, značajnu ulogu imaju i demografski čimbenici. Hipoteza životnog ciklusa naglašava dobnu strukturu stanovništva, gdje mlađa i starija ovisna skupina imaju relativno mali udio u štednji. Loayza at el. (2000) istražuje utjecaj ovisne skupine i urbanog stanovništva na nacionalnu štednju te potvrđuju negativan statistički značajan utjecaj ovisne skupine na razinu štednje, dok je determinanta urbanog stanovništva negativna, ali statistički neznačajna. Schrooten i Stephan (2004) u skladu sa ranijim istraživanjima, dokazuju pozitivan utjecaj dohotka na stopu privatne štednje u Europi, te naglašavaju veći utjecaj dohotka na duži period u odnosu na kraći period.

Hüfner i Koske (2010) provode analizu nad zemljama G7 kako bih objasnili rast stope štednje kućanstva Njemačke za razdoblje nakon 2000-te godine. U odnosu na prethodne promatrane studije, autori, pored tradicionalnog sagledavanja hipoteze životnog ciklusa, testiraju učinak bogatstva, uključivanjem cijena nekretnina i cijena na tržištu kapitala. Potvrđuju utjecaj bogatstva putem cijena dionica, dohotka i kamatnih stopa na odluke o štednji kućanstva.

Temelj Loayza at el. (2000) istraživanja koriste Grigoli at el. (2014) te analiziraju široki skup zemalja, istražuju razlike u štednji kroz vrijeme i zemlje. Fokus istraživanja je usporedba privatne, nacionalne, korporativne i štednje kućanstva kao i analiza razdoblja financijske krize. Potvrđuju pozitivan doprinos dohotka na štednju te dokazuju pozitivan utjecaj inflacije izazvan motivima predostrožnosti. Determinanta urbanog stanovništva i ovisne skupine pokazuju statističku značajnost i negativan utjecaj na nacionalnu i štednju kućanstva.

Kolasa i Liberda (2014) razmatraju utjecaj ekonomskih i demografskih determinanti na privatnu štednju i štednju kućanstva Poljske te ih uspoređuje sa razvijenim zemljama. Potvrđuju značajan utjecaj realne kamatne stope, štednje države i privatnog sektora sa cikličnim čimbenicima na štednju kućanstva OECD zemalja, dok je demografska determinanta – starija ovisna skupina, beznačajna. Nadalje, potvrđuju promjene u stopi štednje kućanstva Poljske posljednjeg desetljeća uglavnom uzrokovane promjenama financijskog duga i stope rasta prihoda kućanstva. Ispitivanjem determinanti i uspoređivanjem potvrđuju veću osjetljivost Poljske na financijsko produbljivanje u odnosu na OECD zemlje.

Rocher i Stierle (2015) ukazuju kako nezaposlenost i stopa inflacije kao mjere makroekonomske nesigurnosti imaju statistički značajan i pozitivan utjecaj na razinu štednje u zemljama EU. Vrijednost kamatne stope ne ukazuje na značajan efekt, dok Kukk i Staehr (2015) provode analizu na deset članica Srednje i Istočne Europe te ukazuju na pozitivan utjecaj realne kamatne stope na štednju kućanstva, a ne pronalaze povezanost kamatne stope sa štednjom korporativnog sektora.

1.2. Predmet istraživanja

Predmet istraživanja diplomskog rada jesu ekonomske i demografske determinante štednje kroz grupu 13 odabranih zemalja Europske unije u razdoblju 2000.-2016. godine.

Prilikom empirijskog istraživanja ispitivat će se utjecaj BDP po glavi stanovnika, inflacije, nezaposlenosti, kamatne stope, demografske ovisnosti, udjela urbanog stanovništva na razinu

štednje u izabranim članicama EU. Uz navedeno, ispitat će se utjecaj navedenih varijabli tijekom razdoblja globalne financijske krize. Isto tako, pružit će se analiza instrumenata štednje.

1.3. Istraživačke hipoteze

Na temelju definiranog problema i predmeta istraživanja, postavljaju se hipoteze koje će se ispitati empirijskom analizom. Hipoteze diplomskog rada su sljedeće:

Ekonomske determinante:

$H_{1.1}$: Dohodak pozitivno utječe na razinu štednje

Promatrana istraživanja i pretpostavke analitičara objašnjavaju dohodak kao temeljnu varijablu utjecaja na obujam štednje. Naglašava se pozitivan utjecaj dohotka na obujam štednje; nacionalne, korporativne i kućanstva. Ovakav smjer objašnjava se na način da je pojedinac spremniji na povećanje štednje i potrošnje uslijed rasta dohotka. Isto tako, prema Keynes-ovoj tvrdnji „temeljni psihološki zakon" pojedinac povećanjem dohotka smanjuje proporciju dijela potrošnje, a povećava proporciju štednje. Promatrana empirijska literatura koristi raspoloživi dohodak kao varijablu koja je mjerena BDP-om po glavi stanovnika, najčešće zbog dostupnosti podataka.

$H_{1.2}$: Inflacija utječe na razinu štednje

Inflacija je porast razine cijena u odnosu na prethodno razdoblje ili pad vrijednosti novca. Inflacija uzrokuje neizvjesnost, promjenu ponašanja pojedinca i gubitak povjerenja u novac što uzrokuje promjenu u strukturi štednje. S teorijskog stajališta, ističe se dvosmislen i nejasan utjecaj inflacije na štednju.

Muradoglu i Taskin (1996) navode argument intertemporarne potrošnje da očekivanja inflacije mogu poticati potrošnju roba široke potrošnje na *štetu štednje*, dok Grigoli et al. (2014) ističu gubitak povjerenja pojedinca u financijske instrumente i institucije u situaciji makroekonomske, financijske i političke nestabilnosti uzrokovane i mjerene razinom inflacije, što *negativno* utječe na stopu štednje. Isto tako, Kukk i Staehr (2015) naglašavaju smanjenje duga poduzeća uslijed inflacije što može uzrokovati dodatno zaduživanje, odnosno *negativnu* povezanost inflacije i štednje.

Pozitivan utjecaj inflacije se objašnjava kroz makroekonomsku nesigurnost i gubitak financijske imovine. Pojedinac pri visokoj razini inflacije, kao mjere makroekonomske nesigurnosti, ima tendenciju *povećati* razinu štednje iz predostrožnosti.

Dodatno, visoke stope inflacije utječu na dohodak. Mirovine koje nisu u skladu sa varijacijom cijena, gube na nominalnoj vrijednosti kao i radnici prilikom dobivanja plaća ukoliko cijene i nadnice ne rastu proporcionalno. Navedena situaciju stavlja pojedinca u položaj gubitka financijske imovine uslijed čega iz psiholoških motiva nadoknade izgubljenog *povećavaju stopu štednje.*

$H_{1.3}$: Nezaposlenost determinira razinu štednje

Nezaposlenost je položaj u kojemu dio radno sposobnih članova društva ne može ostvariti temeljni dohodak svojim radom. Utjecaj nezaposlenosti na štednju može biti i pozitivan i negativan.

Nezaposlenost se u empirijskim ispitivanjima koristi kao mjera makroekonomske nesigurnosti. Promatrane empirijske studije objašnjavaju *pozitivan utjecaj* varijable 'nezaposlenost' na štednju iz predostrožnosti od gubitka radnih mjesta i dohotka u budućnosti. Uslijed visoke stope nezaposlenosti, pojedinac osjeća strah od gubitka radnog mjesta i tekućeg dohotka, što je *motiv za štednju* pojedinca.

Isto tako, naglašava se *negativan utjecaj* na dohodak i štednju uslijed visoke stope nezaposlenosti. Naime, dohodak se smanjuje što uvjetuje smanjenje raspoloživih sredstava za štednju.

$H_{1.4}$: Kamatna stopa utječe na razinu štednje

Istraživanje utjecaja kamatne stope na štednju ne ukazuje na jednoznačan zaključak. Muradoglu i Taskin (1996) učinak kamatne stope objašnjavaju efektom inflacije uz uvjet nepromijenjene nominalne kamatne stope, što djeluje na smanjen trošak zaduživanja. Navedena pretpostavka uzrokuje povećanje potrošnje i *smanjenu stopu štednje*. Rocher i Stierle (2015) objašnjavaju učinak rasta kamatne stope na efekt dohotka uslijed kojeg pojedinac povećava trenutnu potrošnju bez utjecaja na buduću, što *uvjetuje manju stopu štednje.*

Prema teoriji klasičnih ekonomista rast kamatne stope znači veću nagradu za odricanje od sadašnje potrošnje, što utječe na *porast* štednje. Kolasa i Liberda (2014) objašnjavaju supstitucijski efekt kamatne stope, tj. rast kamatne stope povećava troškove tekuće potrošnje u odnosu na buduću potrošnju što uzrokuje *povećanje štednje.* S druge strane, Keynes (1936) navodi kamatnu stopu kao nagradu za odricanje od likvidnosti.

Demografske determinante:

$H_{2.1}$: Broj o hranitelju obitelji ovisnih članova utječe na razinu štednje

Struktura, odnosno veličina obitelji, utječe na razinu štednje. Smjer utjecaja može biti i pozitivan i negativan. Analizirana istraživanja ističu potrebe za potrošnju s obzirom na veličinu obitelji. Velika obitelj odvaja veći dio dohotka za potrošnju što dovodi do smanjenja štednje, dok obitelji sa manjim brojem članova izdvajaju manji dio za potrošnju. Isto tako, mlađa kućanstva, sa djecom, troše više a manje štede u usporedbi sa starijim kućanstvima. S druge strane, radi brojnih motiva, prvenstveno predostrožnosti i brige za budućnost djece, obitelji sa mlađom populacijom imaju tendenciju štednje.

$H_{2.2}$: Udio urbanog stanovništva negativno utječe na razinu štednje

Analizirana literatura ističe negativan utjecaj stope urbanog stanovništva na razinu štednje. Naglašava se značajnost grada, prilika i mogućnosti koje pruža pojedincu u obliku potrošnje, stabilnog dohotka uslijed kojeg nema motiva štedjeti zbog predostrožnosti. Urbano stanovništvo štedi manje u odnosu na ruralno stanovništvo koje je obilježeno nesigurnim dohotkom, manjom zastupljenošću kreditnih prilika, što utječe na veće stope štednje.

Utjecaj krize na razinu štednje:

$H_{3.1}$: Financijska kriza utječe na štednju

S obzirom na razmjer i posljedice globalne krize, ovom hipotezom će se ispitati njezin utjecaj na štednju u promatranim zemljama EU. Razdoblje krize obilježeno je značajnim padom dohotka stanovništva, varijacijama kamatnih stopa i iseljavanjem stanovništva iz slabije razvijenih u razvijene zemlje, kao i promjenom dobnih granica. Zbog smanjenog dohotka uslijed krize, manje su mogućnosti za štednju. S druge strane, u situaciji krize stanovništvo može biti motivirano na štednju iz predostrožnosti.

1.4. Ciljevi istraživanja

Temeljni cilj istraživanja je ispitati utjecaj ekonomskih i demografskih determinanti na razinu štednje. Pored osnovnog cilja, u radu će se objasniti teorijski okvir štednje, pojam, motivi i instrumenti štednje. Dakle, ciljevi istraživanja uključuju utvrđivanje teorijskih pretpostavki ekonomskih i demografskih determinanti koje utječu na stopu štednje. Također, pružit će se analiza štednog potencijala i obujma štednje u odabranoj grupi zemalja EU. Isto tako, uvidjet

će se postoji li promjena utjecaja odabranih determinanti na razinu štednje uslijed nastupanja globalne financijske krize.

1.5. Metode istraživanja

Znanstvena metodologija sadržavat će nekoliko različitih metoda koje će se primjenjivati ovisno o teorijskom ili empirijskom dijelu rada.

Metoda analize kategorizirat će složene dijelove na jednostavne, zbog jasnijeg razumijevanja. Povezivanju jednostavnih teorijskih okvira doprinosit će metoda sinteze. Prilikom opisivanja činjenica i procesa, tj. pojma, motiva i povijesnog pregleda štednje koristit će se deskriptivna metoda. Putem navedene metode objasnit će se uzročno–posljedična povezanost determinanti i razine štednje, a u kombinaciji sa metodom apstrakcije i konkretizacije artikulirat će se stavovi. Istraživanje će pružiti i istaknuta mišljenja/zaključak autora u području štednje, što će uključivati metodu kompilacije.

Teorijski dio rada fokusirat će se na prikupljanje i analiziranje stručne i znanstvene literature, donošenje jasnih zaključaka i stavova, što će uključivati metodu indukcije i dedukcije.

Korištena literatura odnosit će se na znanstvene i stručne članke, na engleskom jeziku, te manji dio, zbog nedostatka, na hrvatskom jeziku. Literatura će biti pretraživana putem različitih Internet izvora, a baza podataka kreirana temeljem baze podataka sa Ameco, Eurostat, European Central Bank, OECD Database, World Bank Group Database. Podaci će se prikupiti za 13 zemalja u razdoblju 2000.-2016. godine. Empirijski dio bazirat će se na panel analizi putem statističkog programa STATA.

1.6. Doprinos istraživanja

Istraživanje obuhvaćeno ovim radom bavit će se problematikom štednje, nastojat će ukazati na značaj temeljnih determinanti štednog potencijala. Ovim radom omogućit će se bolje razumijevanje teorijskih okvira štednje, a empirijski dio rada omogućit će uvid u trendove i trenutna stanja važnosti i intezitet temeljnih ekonomskih i demografskih determinanti štednje što je od važnosti za kreiranje ekonomskih politika.

1.7. Struktura diplomskog rada

Nakon uvoda, drugo poglavlje, definirat će teorijske okvire i motive štednje, te će se kategorizirati struktura mogućih instrumenata štednje. Cilj teorijskog dijela će biti pružanje jasnog uvida i razumijevanje u pojam, motive i instrumente štednje.

Treće poglavlje pružit će pregled literature, teorijskih pretpostavki i empirijskih istraživanja na temu analize štednje. Analizirat će se ekonomske i demografske varijable koje imaju utjecaj na razinu štednje.

Četvrto poglavlje prikazat će analizu štednje u izabranim zemljama. Pružit će uvid u stope štednje za izabrane članice te utvrditi zaključke i poveznice sa teorijskim spoznajama navedenim u trećem poglavlju.

Peto poglavlje odnosit će se na empirijski dio, koji će pružiti detaljni uvid u rezultate provedenog istraživanja. Kroz poglavlje će biti objašnjenja korištena metodologija i podaci nad kojim je primjenjena analiza kao i sami izvori podataka. Analiza će ispitivati utjecaj ekonomskih i demografskih determinanti na razinu štednje kroz izabranu grupu zemalja. Ovo poglavlje će sadržavati interpretaciju dobivenih rezultata i grafički prikaz.

Šesto poglavlje će se odnositi na utvrđivanje zaključka koji će iznijeti glavne rezultate, spoznaje i pretpostavke autora na temelju istraživanja i pregledanih stručnih i znanstvenih članaka. Na kraju rada pružit će se uvid u korištenu literaturu.

2. ŠTEDNJA

2.1. Teorijske osnove štednje

Teorijske spoznaje štednje trajni su interes i promišljanje ekonomske misli. Među brojnim objašnjenjima pojma štednje ističe se „Štednja – čuvanje materijalnih dobara od upotrebe ili potrošnje u korist relativno važnije buduće potrošnje, posredstvom novca ili bez njega“ (Pojatina, 1981, str. 6). Teorije štednje su brojne, a potencijal neiscrpan, određen ekonomskom politikom, mjerama i instrumentima što objašnjava važnost istraživanja determinanti štednje.

2.1.1. Teorije kamatne stope

Teorija klasičnih ekonomista predstavlja ***kamatnu stopu*** kao faktor koji uravnotežuje potražnju i ponudu štednje, tj. kao točku u kojoj je obujam investicija (potražnja za štednjom) jednak iznosu ponude štednje. Klasični ekonomisti naglašavaju *kamatnu stopu kao temeljnu determinantu štednje* te ističu Bohm Bawerk-ovu *„vremensku prednost“* koja objašnjava sklonost pojedinca prema tekućim dobrima u odnosu na manje vrijedna buduća dobra. S obzirom na vremensko opadanje vrijednosti dobara klasična teorija promatra *kamatnu stopu* kao nadoknadu opadajuće vrijednosti. Prema navedenoj teoriji, pojedinac prihvaća štednju ukoliko će korisnost buduće potrošnje biti jednaka ili veća od korisnosti tekuće potrošnje.

Nadalje, „stav klasične teorije da je potražnja za kapitalom određena prosudbama poduzetnika o budućoj rentabilnosti iz kapitalnih dobara, troška tih dobara i kamatnih stopa. Ukoliko neto učinci iz produktivno uporabljivih dobara ili budući prihodi umanjeni za troškove dobara prelaze visinu kamate, poduzetnici će se zaduživati i nabavljati dobra“ (Pojatina, 2000, str. 9).

Nasuprot mišljenju klasičnih ekonomista, *Keynes* naglašava prijepor u mišljenju i stavovima kada je riječ o *utjecaju kamatne stope na sklonost štednji*. Isti autor iznosi stajalište da razina dohotka značajno utječe na obujam štednje dok tekuća kamatna stopa može imati utjecaj na štednju iz datog dohotka. Isto tako, *Keynes osporava tvrdnju klasične teorije* o pozitivnom odnosu kamatne stope i obujma stvarne štednje. Negativan utjecaj kamatne stope objašnjava putem značajnog utjecaja na investicije koje su determinanta dohotka. Rast kamatne stope do povoljne granice za investiranje potiče na štednju uz nepromijenjeni dohodak. Stoga, Keynes zaključuje da „klasična teorija nije imala osjećaj za važnost promjena u razini dohotka ili za mogućnost da razina dohotka zapravo bude funkcija kamatne stope“ (Keynes, 1936, str. 112).

Također, smatra da se psihološki motiv pojedinca dugoročno može zadovoljiti rastom kamatnih stopa s obzirom da kamatnu stopu promatra kao nagradu za odricanje od likvidnosti,

olakšavajući pojedincu izbor instrumenta ulaganja novca. Prema tome, značajan utjecaj varijacija kamatne stope na štednju ostvaruje se kroz slučajan značajni rast ili pad vrijednosti imovine pojedinca na tržištu kapitala.

2.1.2. Teorija dohotka

Hipotezu apsolutnog dohotka razvija J.M. Keynes čije je proučavanje štednje temeljeno na potrošnji kao funkciji dohotka. Zagovara tvrdnju da potrošač određuje dio dohotka koji odvaja za potrošnju, a štednja predstavlja nepotrošeni dio dohotka. U odnosu na promišljanje klasičnih ekonomista, Keynes, sagledava *veličinu dohotka kao glavnu determinantu štednje* te proučava *teoriju sklonost potrošnji*.

S teorijskog stajališta, Keynes (1936) sklonost potrošnji objašnjava kroz odnos *potrošnje* izražene u jediničnim nadnicama s *dohotkom* izraženim u jediničnim nadnicama pri zadanoj razini zaposlenosti. Kritike navedenog, odnose se na varijacije u vrijednostima dohotka pri različitim strukturama zaposlenosti.

Nadalje, autor uz dohodak, ističe *objektivne* i *subjektivne* faktore koji determiniraju ponašanje i sklonost pojedinca za potrošnju. Proučavanjem faktora utjecaja, Keynes naglašava važnost *stvarnog dohotka i provedbe fiskalne politike* u kreiranju sklonosti potrošnje s obzirom na stav pojedinca. Slučajne *promjene vrijednosti kapitala*, fiskalna politika kroz *provedbu porezne regulacije* i značajne *promjene kamatne stope* sposobne su promijeniti vrijednosti stvarnog dohotka što uzrokuje promjenu sklonosti potrošnje.

S obzirom na zaključak o *sklonosti potrošnji* kao relativno *stabilnoj funkciji*, koja značajno ne ovisi o drugim faktorima osim dohotka, Keynes (1936) razvija teoriju o odnosu potrošnje i dohotka kroz temeljni psihološki zakon s obzirom na psihološke osobine ljudske prirode u smislu da rast dohotka ne uzrokuje proporcionalan rast potrošnje, već se povećava proporcija štednje.

Psihološki aspekt objašnjava da pojedinac povećava svoju potrošnju sa povećanjem dohotka, ali ne u iznosu u kojem se povećava dohodak. U kratkom roku, ne postoji mogućnost adekvantne prilagodbe promjenjenim uvjetima s obzirom na naviknuti životni standard. Isto tako, povećanje dohotka uzrokuje veću razliku dohotka i potrošnje, jer zadovoljavanjem postavljenih standarda ugodnog života jača potreba za štednjom. Nasuprot Keynes-ovom proučavanju teorije sklonosti potrošnji u kratkom roku, *Kuznets* pokazuje paradoks **(*Kuznets paradox*),** kroz istraživanje funkcije potrošnje koristeći dugotrajne vremenske serije (Alimi,

2013). „*Kuznets* empirijskom studijom prikazuje prosječnu sklonost potrošnji u rasponu 0,84 – 0,89 za razdoblje 1869 – 1938“ (Baykara i Telatar, n.d., str. 3,4.). Na temelju navedenih spoznaja prema kojima „povećanjem dohotka potrošnja ostaje relativno *stabilni udio dohotka*, *Kuznets* tvrdi da je potrošnja *udio*, a ne funkcija dohotka“ (Baykara i Telatar, n.d., str. 3,4.).

Keynes-ova teorija apsolutnog dohotka uzrokovala je brojne teorijske studije i promišljanja ekonomskih analitičara što je dovelo do novih hipoteza. Najpoznatije su *teorije relativnog i permanentnog dohotka, te hipoteza o životnom ciklusu.*

Pojatina (2000) i Babić (2007) ističu Duesenberry-vu (1967) ***hipotezu relativnog dohotka*** koji naglašava *„demonstracije“* i *„ugledanja“* kao uzrok povećane potrošnje i bez povećanja dohotka, odnosno potrošnja ovisi o odnosu dohotka pojedinca i dohotku njegovih susjeda, a ne o apsolutnoj razini dohotka. U slučaju smanjenog ili nepromijenjenog dohotka u odnosu na kategoriju ljudi kojoj pripada pojedinac, smanjuje se relativni položaj, životni standard pojedinca. Da bi sačuvao životni standard, pojedinac povećava udio potrošnje na štetu štednje. Prema navedenom, u slučaju nepromjenjenog dohotka pojedinca u odnosu na povećanje dohotka ostalih, Babić (2007) ukazuje da osobe s nižim dohotkom imaju veću sklonost potrošnji. Navedeno otkriva da tekuća potrošnja u kratkom roku ne mora ovisiti o tekućem dohotku. Duesenberry (1967) zaključuje: rast dohotka povećava potrošnju, a nova ravnotežna pozicija ostvaruje se na na višoj razini dohotka.

Temeljna razlika u odnosu prve dvije teorije i ***teorije permanentnog dohotka***, naglašena je u egzogenoj varijabli, pri čemu se koristi permanentni dohodak, umjesto tekućeg dohotka. Nadalje, Friedman (1957) dijeli dohodak i potrošnju na permanentni i tranzitorni dio. Dok permanentni dohodak kao procjena budućih prihoda utječe na potrošnju, stav autora o tranzitornom dohotku, koji je promjenjiv, kao posljedici slučajnih faktora, je da u kratkom roku ima utjecaj na štednju, a ne potrošnju.

Temeljeno na Friedman-ovim teorijskim promišljanjima, Ando i Modigliani (1963) razvijaju ***teoriju životnog ciklusa***. Ova teorija naglašava da sklonost štednji ili potrošnji ovisi o životnoj dobi, odnosno prema očekivanom dohotku koji će pojedinac ostvariti tijekom životnog vijeka. Najveća razina štednje obilježena je u radno aktivnom razdoblju pojedinca, koju karakterizira trend rasta do određenog vremena nakon kojeg ostvaruje pad. Navedena teorija objašnjava se kroz ulogu radno aktivnog pojedinca koji s obzirom da zarađuje više od troškova, akumulira svoju štednju za mirovinu ili otplaćuje dugove stvorene tijekom školovanja.

2.1.3. Neoklasična načela

Prema *neoklasičnom tumačenju*, sklonost štednji se podiže pod utjecajem povećanja kamatne stope jer povećanje kamatnih stopa čini buduće prihode većim i sadašnju potrošnju skupljom u odnosu na buduću. Također, smanjenjem sadašnje vrijednosti financijskih aktiva, odnosno postojećih prava na budući dohodak, koji proizlazi iz povećanja kamatne stope, sa svoje strane vodi povećanju stopa štednje (Pojatina, 2000, str. 14). Ističe se *„efekt Pigou"* koji proučava kretanje cijena na povezanost potrošnje, bogatstva, proizvodnje i zaposlenosti. Prema navedenom, uslijed deflacije povećava se potrošnja i zaposlenost kao posljedice povećanja bogatstva i kupovne moći likvide imovine. Obrnuti utjecaj tumači se za inflaciju.

2.2. Instrumenti štednje

U ovom poglavlju će se objasniti instrumente koji pojedincu pružaju mogućnost ulaganja uštođenog dijela dohotka.

2.2.1. Depoziti

Depoziti se smatraju osnovnim bankarskim izvorom novčanog potencijala, a Rose (2003, str. 387.) ističe „depozite kao temelj na kojem banke napreduju i rastu, s obzirom da oni stvaraju zakonske rezerve, a iz viška zakonskih rezervi koje banka posjeduje, stvaraju se novi krediti".

Transakcijski depoziti

Početak razmatranja depozita odnosi se na transakcijske depozita čija je osnovna funkcija izvršavanje platnih transakcija za komitenta. Mogućnost ugovaranja ovakvog tipa depozita pospješila je tehnološka revolucija, dostupnost jednostavnog i brzog interneta te mobilnog bankarstva. Kategorije transakcijskih depozita kao mogućnost za pojedinca su *beskamatni depoziti po viđenju* i *kamatnonoseći depoziti po viđenju*. Korištenjem usluga depozita po viđenju karakterizira spremnost deponenata za odricanjem kamatnog prihoda u svrhu pristupa likvidnim sredstvima na zahtjev. ***Beskamatni depoziti po viđenju*** s obzirom na varijacije priljeva i odljeva novčanih sredstava koje karakteriziraju depoziti po viđenju kao i njihova ročna struktrura, nisu određeni sa kamatnim priljevom za deponenta. Korist i motiv deponenta prilikom otvaranja ovakvog tipa računa odnosi se na mogućnost podizanja sredstava bez ograničenja, usluge plaćanja, sigurnost novčanih sredstava. Najpoznatiji su *žiro i tekući račun.*

„Žiro-račun u najvećoj mjeri koriste poslovni subjekti za obavljanje poslovanja, dok građani primaju dodatne prihode koje ostvaruju" (Gregurek i Vidaković, 2013, str. 133). Prilikom poslovanja s inozemstvom koristi se *devizni žiro-račun*, pri čemu također postoji mogućnost

otvaranja podračuna za nekoliko valuta kojim se trguje. S druge strane, „***tekući račun*** je osnovni račun za dnevne transakcije koje ostvaruju građani“ (Gregurek i Vidaković, 2013, str. 132). U konačnici pruža mogućnost kredita, do ugovorenog limita u odnosu na *žiro-račun* koji je određen samo dostupnim sredstvima. Banka putem ovih depozita ubrzava proces trgovine, smanjuje troškove plaćanja i pridonosi razvoju tržišta. Isto tako, „određena količina novca na ovim računima usmjerava se u kreditne plasmane što doprinosi depozitnoj multiplikaciji“ (Katunarić, 1988, str. 239). ***Kamatnonoseći depoziti po viđenju*** osiguravaju specifične uslugu deponentima uz mogućnost kamatnih prihoda.

Netransakcijski depoziti

Netransakcijski depoziti su najznačajniji izvori novčanih sredstava banaka zbog svog dugoročnog karaktera. Ročna struktura koja osigurava bankama sigurnost ulaganja sredstava i likvidnost određuje kamatne stope na višoj stopi u odnosu na depozite po viđenju. Odluka o ulaganju ovakvog tipa depozita motivirana je kamatnim prihodima koja se ostvaruje ovisno o iznosu sredstava i ugovorenom dospijeću ulaganja. Ističu se *štedni i oročeni računi.*

Štedni račun je oblik srednjoročne štednje koji pruža mogućnost pohrane novčanih sredstava uz određenu kamatnu stopu. Institucije provode transkacije trajnim nalogom putem kojeg se odvaja dogovorena svota za štednju uz ograničenja mjesečnih isplata. Pored navedenog, pojedinac postiže mogućnost podizanja potrebne svote uz obračunavanje smanjene kamatne stope. Korist za štednju pojedinca pored kamatnih prihoda određen je životnim događajima koji motiviraju na dječju štednju, premijsku štednju, štednju za školovanje, za mirovinu.

Model ostvarivanja viših prinosa na uložena sredstva pojedinca postiže se korištenjem ***oročenih depozita*** koji je određen datumom dospijeća. Mogućnost korištenja i dostupnosti sredstava je ograničena za ulagača što omogućuje bankama dugoročno planiranje prilikom plasiranja sredstava. S obzirom na princip dugoročnog dospijeća, pojedinac putem *oročenih depozita* ostvaruje najveće kamatne stope u komparaciji sa bankarskim uslugama.

S aspekta banke, pored navedenog ističu se *certifikati o depozitu (CD)*. Navode se kao hibridni instrument koji bankama omogućuje aktivno upravljanje pasivom. Mishkin (2010) ističe *prenosivost* kao karakteristiku CD-a, odnosno mogućnost plasiranja na sekundarnom tržištu s obzirom da se ovaj instrument izdaje na velike razine novčanih vrijednosti.

2.2.2. Ulaganje u instrumente nebankovnih financijskih institucija

Investicijske institucije su pravne osobe čija je osnovna djelatnost prikupljanja i plasmana novčanih sredstava kreirana kupoprodajom vrijednosnih papira. Isto tako, koncentracija novca obavlja se putem naplate premija osiguranja i uplata doprinosa za mirovinsko osiguranje. Korist za pojedinca ne osiguravaju dogovorenom kamatnom stopom, već prinosi ovise o kretanju uloženog portfelja institucija.

Ulaganje u instrumente investicijskih fondova

Funkcija investicijskih fondova je *distribucija štednje pojedinca* na financijska tržišta. S obzirom na nemogućnost pristupa financijskim tržištima zbog nedostatka kapitala i znanja pojedinca, stanovništvu je putem financijskih institucija ili institucionalnih investitora omogućeno diversificirano ulaganje i zarade. Investicijski fondovi osiguravaju koncentraciju novčanih sredstava emisijom vrijednosnih papira te ulažu u diversificirani portfelj s namjerom smanjenja rizika, povećanju profitabilnosti i sigurnosti za ulagača. Motiv pojedinca prilikom odluke o plasiranju sredstava u investicijske fondove određen je ***strategijom upravljanja*** pojedinog fonda, averzijom prema riziku pojedinca i osobnim preferencijama. *Strategija aktivnog upravljanja* fonda odnosi se na ulaganje u odabrani segment investicija. Ugovaranjem ovakvog tipa ulaganja pojedinac je motiviran većim prinosima u odnosu na tradicionalne instrumente ulaganja, primjerice bankovnih depozita. Pristup *pasivnog upravljanja* oslanja se na „dugoročni gospodarski rast koji utječe na stabilne prinose formiranog imovinskog portfolio fonda, tj. indeksni fond“, (Orsag, 2011., str. 69). Profitno rizična obilježja razmatraju se u kontekstu strategijske uloge i tipa investicijskog fonda[1]. Osnovno proučavanje fondova promatra se kroz mogućnosti emitiranja udjela; postoje *otvoreni i zatvoreni investicijski fondovi*. „Otvoreni financijski fondovi prikupljaju kapital emisijom jedinica, odnosno udjela u fondu“ (Orsag, 2011., str. 67), a ulagači su ujedno vlasnici fonda čija je struktura kapitala promjenjiva s obzirom na neograničenost visine obujma emitiranja udjela fonda. U odnosu na ovaj tip fonda, *zatvoreni investicijski fondovi* emitiraju dionice čiji je broj unaprijed ograničen. Prilikom ulaganja pojedinac ima mogućnost sudjelovanja u dobiti i isplati dividendi s obzirom da dionice kotiraju na burzi, što nije moguće ulaganjem u otvoreni tip fonda. Isto tako, zatvoreni fond upravlja investicijama poput otvorenog fonda, te aktivnosti djelovanja koristi i za

[1] Kategorije fondova dijele se na fondove dionica, obveznica, mješovite i novčane fondove ovisne o strukturi rizika i prinosa. Navode se fondovi ulaganja u nekretnine i zlato, dok sa stajališta profitno rizičnih karakteristika (Orsag, 2011., str. 70) ističe dohodovne i rastuće fondove.

ostvarivanje drugih poslovnih ciljeva. Orsag (2011) navodi značajnu pojavu *specijaliziranih investicijskih fondova* za rizična ulaganja te *privatizacijske investicijske fondove* koje pružaju mogućnost ulaganja pojedinca.

Ulaganje u instrumente društava za osiguranje

Društva za osiguranje pružaju usluge prodajom police osiguranja te za to ostvaruju naknadu, premiju od ugovaratelja osiguranja. Ekonomska potreba pojedinca za dugoročnom štednjom i pokrivanjem rizika osigurava se ugovaranjem životnog osiguranja. Prema Andrijašević "štedna funkcija životnog osiguranja jest da novac koji se ulaže u premiju osiguranja oplođuje se uz zadanu kamatnu stopu" (Andrijašević i Petranović, 1999., str. 123). Rizike koji se pokrivaju ugovaranjem životnog osiguranja, Andrijašević i Petranović (1999) ističu smrt hranitelja, školovanje djece, mogućnost korištenja kao jamstvo za dobivanje kredita, zaštita partnerstva te osiguranje poslovnim jedinicama u slučaju prestanka rada ključnih ljudi u poduzeću. S obzirom na sklonost pojedinca prema riziku, najčešće određeni *stupanj averzije prema riziku*, navedni oblik ulaganja i obilježja utječe na motiv pojedinca. S aspekta poduzeća, ugovaranjem životnog osiguranja osigurava se od mogućeg gubitka uslijed smrti zaposlenika ili nesposobnosti za obavljanje rada. Kategorije ugovora o životnom osiguranju odnose se prema načinu plaćanja premije i participacije vlasnika police u dobiti. Isto tako, Ćurak i Jakovčević (2007) navode četiri osnovne kategorije životnog osiguranja; „osiguranje za slučaj smrti (s određenim rokom trajanja i doživotno osiguranje za slučaj smrti), mješovito osiguranje (osigurava se financijska sigurnost u slučaju prerane smrti i ukoliko osiguranik nadživi ugovor), rentno osiguranje (osigurane su isplate novca za neko razdoblje ili do kraja života u slučaju uplate ugovorene vrijednosti premije) te ostala životna osiguranja (ovisna o ugovorenom pokriću rizika, obračuna premija, osiguranih svota i raspodjele prinosa“.

Ulaganje u mirovinske fondove

Mirovinski fondovi pružaju mogućnost štednje pojedincu kroz radno aktivni period života, a tijekom mirovine pojedinac ima pravo na isplatu akumulirane uštedevine. Struktura fonda pojavljuje se kao javna i privatna, također mirovinsko osiguranje može biti s definiranim *iznosom isplate ili dogovorenim uplatama doprinosa*. Isto tako, Saunders i Cornett (2006) klasificiraju mirovinski fond na ***osigurani i neosigurani*** *mirovinski fond*[2] čija je temeljna

[2] Osigurani mirovinski fond je fond kojim upravlja tvrtka za životno osiguranje, dok financijska institucija koja nije tvrtka za životno osiguranje upravlja neosiguranim mirovinskim fondom, (Saunders i Cornett, 2006., str. 506, 507.)

razlika u investiranoj aktivi pojedinog mirovinskog fonda. Mirovinsko osiguranje definirano *dogovorenim uplatama doprinosa* osiguravaju isplatu mirovina na temelju uspješnosti fonda. Aktualnost radnih uvjeta i osiguranja kvalitetne mirovine u obliku mjesečne rente utjecali su na značajna sredstva ulaganja poslodavaca kao postotak plaće djelatnika. S druge strane, mirovinsko osiguranje definiranog *iznosom isplate* pokrovitelj osiguranja obvezuje se na isplatu djelatnicima pri odlasku u mirovinu. Novčani iznos određuje se s obzirom na godine radnog staža i visine plaće u radnom periodu. Mirovinski fondovi, društva za osiguranje i investicijski fondovi uvrštavaju se u kategoriju značajnih institucionalnih investitora na tržištu kapitala. Interes ulagača ostvaruju ulaganjem u vrijednosne papire država, korporativne i strane obveznice, te dionice.

2.2.3. Ulaganje u vrijednosne papire

Mehanizam financijskih tržišta usmjeren je procesu kupoprodaje vrijednosnih papira. (Orsag, 2011., str. 3) ističe „značaj vrijednosnica za stvaranje univerzalnih homogenih financijskih instrumenata dostupnih širokoj investicijskoj javnosti“. S aspekta poduzeća, predstavljaju instrumente financiranja, dok za pojedinca proizlazi korist ulaganja viška novčanih sredstava.

Dionice su ***dugoročni vrijednosni papiri*** u obliku pisane isprave koje definiraju prava i obveze ulagača u pojedinom dioničkom društvu. (Orsag, 2011., str. 580) definira dionice kao „sredstvo posredovanja između investicija dioničkog društva i štednje pojedinca“. Emitiranje dionica imaju pravo dionička društva, odnosno korporacije, na primarnim tržištima, a daljna kupoprodaja kao posljedica brojnih motiva odvija se na sekundarnim tržištima.

Emisijom dionica korporacija formira vlasnički kapital te prikuplja novčana sredstva za kapitalne projekte. S druge strane, Orsag (2011) kao motive *investitora,* prilikom ulaganja u dionice navodi visoki stupanj mobilnosti dionice, supstitut novcu i mogućnost prinosa (dividendi) ili kapitalnih dobitaka. U ovisnosti uloženog, investitor ostvaruje udio u korporaciji, a samim tim i mogućnost prava glasa na skupštini. Navedeni autor ističe ulogu dionice u obliku instrumenta osiguranja za zaduživanje, pologa pri javnim nadmetanjima, instrument plaćanja i instrument osiguranja plaćanja. Isto tako, naglašavaju se dvije vrste dionica sa temeljnim obilježjima: *obične dionice i preferencijalne dionice.* Osnovna obilježja ***obične dionice*** definiraju prava vlasnika i determiniraju vrijednost dionice po kojima se razlikuju od drugih vrijednosnih papira. Najznačajnija su rezidualna prava dioničara koja ujedno određuju i profit, a to su prava na *zaradu i imovinu*. Ostvarena zarada društva iskazuje se kroz isplaćene dividende koje ukazuju na financijsku snagu društva ili porast vrijednosti dionica. „Porast vrijednosti

dionica proizlazi iz profitabilnog reinvestiranja zadržanih zarada što povećava vrijednost za korporaciju i neizvjesnost za ulagača“ (Orsag, 2011, str. 578). S aspekta prava na imovinu, osim mogućnosti prodaje dionice na sekundarnom tržištu, vlasnicima dionica pripada dio likvidacijske mase iako snose rizik s obzirom da su zadnji u redu naplate tražbina prema društvu u slučaju likvidacije društva.

Povlaštene dionice definiraju se kao hibridni vrijednosni papiri koje imaju obilježja običnih dionica i obveznica. Povlaštena dionica pruža vlasnički udio ulagaču, obično bez prava glasa, sa fiksnom dividendom. Ovakav tip ulaganja omogućuje ulagačima isplatu dividendi u slučaju profita i nakon isplate svih vjerovnika, ali prije isplate ulagača običnih dionica. Ovakav tip ulaganja ovisno o pravima na isplatu dividendi dijeli se na tri kategorije: kumulativne, participativne i nekumulativne povlaštene dionice.

S obzirom da se dionicama trguje na sekundarnim tržištima potrebno je odrediti njihovu vrijednost. Izračun cijene dionice je pod utjecajem brojnim determinanti što cjelokupni proces izračuna čini kompleksnijim. Kako bi procjena vrijednosti bila jednostavnija razvijeni su različiti pristupi. Orsag (2006) navodi sljedeće modele za izračun vrijednosti dionice: vrijednost za razdoblje držanja, sadašnja vrijednost dividendi, modeli tržišne kapitalizacije, vrednovanje poduzeća i opcijski pristup vrijednosti.

Obveznica se predstavlja kao ***dugoročni dužnički vrijednosni papir*** kojim pravna osoba prikuplja novčana sredstva na dugi rok. Korporacija emisijom obveznica osigurava stabilan udjel duga u strukturi kapitala namjenjeno financiranju imovine ili kapitalnih projekata nasuprot internom ili eksternom povećanju kapitala. Pored navedenog, koriste se kao instrument osiguranja zaduživanja, instrument pologa pri javnim nadmetanjima te kao instrument osiguranja plaćanja. S obzirom na karakteristike prenosivih vrijednosni papira, tipično kreditni, sa jednokratnim ili višekratnim dospijećem kojim se trguje na sekundarnom tržištu kapitala, investitorima, osiguravaju ulaganja sa visokim stupnjom likvidnosti. Svrha ulaganja u obveznice jest u tome što ograničava rizik insolventnosti visokim stupnjem utrživosti, nadređen položaj prilikom raspodjele rezultata korporacije i likvidacijske mase u odnosu na vlasnike, prinosima u obliku fiksnih kamata i kapitalnog dobitka uslijed rasta cijene obveznica. Nedostatak ulaganja u obveznice postoji kod investitora s malom averzijom prema riziku s obzirom na niske kamatne stope kao posljedica relativne sigurnosti ulaganja, te visoke nominalne vrijednosti prilikom emisije koje imaju za posljedicu privlačenje primarno institucionalnih investitora. Prilikom emisije obveznica određuje se *nominalna vrijednost obveznice* koju je emitent dužan vratiti *po dospijeću* te *kuponska kamatna stopa* uz iznimku za

obveznice bez kupona i fluktuirajuće kamatne stope. Vrijednost obveznice zasniva se procjeni *očekivanih novčanih tokova i rizikom prilagođenoj diskontnoj stopi.*

Orsag (2011) smatra da investitor pored garancije investicijske banke koja posreduje, mora analizirati pokazatelje: pokriće obveznice, kontinuirana isplata kamata, stupanj zaduženosti emitenta i objektivna ocjena boniteta poduzeća emitenta. Najznačajnija kategorija obveznica prilikom klasifikacije odnosi se prema sigurnosti ulaganja za investitora. Ova kategorija izdvaja *državne obveznice* kao najsigurnije, često izjednačene sa nerizičnim financijskim instrumentom; *municipalne obveznice* koje izdaju lokalne uprave i samouprave sa varijacijama u rizično profitnim obilježjima ovisno o karakteru projekta i nositelja; te *korporacijske obveznice* koje čine kategoriju najrizičnijih obveznica, a podložna su brojnim klasifikacijama unutar ove skupine. Općenito promišljanje ekonomskih teoretičara, kao i razmatranje navedenog, može se tvrditi da je ulaganje u obveznice manje rizična investicija u odnosu na ulaganje u dionice.

2.2.4. Ulaganje u nekretnine

Pfnür (2005) objašnjava potrebu za ekonomskim promatranjem *nekretnine* kao ***prostorne i novčane vrijednosti,*** tj. da „nekretnina po sebi nema neku vrijednost, već ta vrijednost nastaje tijekom vremena korištenja nekretnine“ (Pfnür, 2005, str. 19). Brueggeman i Fisher (2008) dijele nekretnine na ***rezidencijalne*** i ***nerezidencijale*** ovisno o udjelu u ekonomskim procesima.

Investiranje u nekretnine smatra se *relativno nerizičnim* ulaganjem, zagarantiranog dugoročnog prinosa što je uzrokovalo prilično veliki udio nekretnina u ukupnoj imovini u pojedinim europskim zemljama. Odluka o ulaganju u nekretnine pod utjecajem je brojnih determinanti, a kao *motive* ulagača, Brueggeman i Fisher (2008) ističu ***potencijalnu stopu povrata, aprecijacija cijena*** tijekom razdoblja zadržavanja nekretnine, odnosno povećanje vrijednosti nekretnine što doprinosi *pozitivnom povratu* za investitora. Isto tako, ***diverzifikacija*** portfelja navodi se kao motiv investitora u svrhu upravljanja rizikom kao i ***porezne prednosti*** u odnosu na alternativne instrumente ulaganja. Pored navedenog, Glickman (2014) ističe ***malu volatilnost povrata*** kao motiv investitora, tj. povrati od investiranja su *stabilni i predvidljivi*. Ulaganje u realnu imovinu, ne podrazumijeva neproduktivne nekretnine. Pojedinac je motiviran uložiti u nekretninu zbog osiguranja stambene situacije, dok poduzeća nekretnine koriste za ostvarivanje prinosa i osiguravanja potreba poslovanja. Niska rizičnost ulaganja i očekivani prinosi utječu na ulaganje raznih institucionalnih investitora. U kontekstu rizičnosti nekretnina pored nerizičnih kategorija navodi se rizična kategorija ulaganja u javne ustanove i rekreacijske nekretnine.

3. DETERMINANTE ŠTEDNJE

U ovom poglavlju pružit će se pregled teorijskih i empirijskih istraživanja o odrednicama štednje. Teorijske studije koriste ekonomske i demografske varijable za procjenu učinka i posljedica njihovih varijacija na kretanje razine štednog potencijala. Empirijska istraživanja provode ispitivanje utjecaja determinanti na stopu štednje; kućanstva, privatne, nacionale i korporacija. Studije razmatraju utjecaj sljedećih kategorija; dohodak, inflacija, bogatstvo, stopa povrata, makroekonomska nesigurnost, fiskalna politika, mirovinski sektor, financijska razvijenost i integracija.

3.1. Ekonomski čimbenici

3.1.1. Dohodak

Promatrana istraživanja i pretpostavke analitičara objašnjavaju dohodak kao temeljnu varijablu utjecaja na obujam štednje. Naglašava se pozitivan utjecaj dohotka na obujam štednje; nacionalne, korporativne i kućanstva. Ovakav smjer objašnjava se na način da je pojedinac spremniji na povećanje štednje i potrošnje uslijed rasta dohotka. Isto tako, prema Keynes-ovoj tvrdnji „temeljni psihološki zakon“ pojedinac povećanjem dohotka smanjuje proporciju dijela potrošnje, a povećava proporciju štednje. Navedena tvrdnja uzrokovala je brojna empirijska istraživanja o ispitivanju doprinosa dohotka na obujam štednje.

Većina empirijskih studija analitičara koristi raspoloživi dohodak[3] kao ključnu varijablu, koja je mjerena pokazateljem BDP ili BDP per capita, i zbog dostupnosti podataka najčešće je korištena varijabla. Dokazivanje odnosa dohotka i štednje s obzirom na Friedman-ove (1957) teorije permanentnog i tranzitornog dohotka, Muradoglu i Taskin (1996) *testiraju stalni i privremeni dohodak kao i rast dohotka na štednju kućanstva*. U sva tri modela, bez obzira na korištenu mjeru, dokazuje se *pozitivan utjecaj na štednju kućanstva u industrijskim zemljama,* dok u kategoriji, *zemlje u razvoju, stalni dohodak negativno utječe na štednju.* Ovakav zaključak, autori objašnjavaju putem gospodarske razvijenosti što uvjetuje različite skupine dohotka i potrošačkih navika između dvije kategorije zemalja. Nerazvijene zemlje, obilježene manjim dohotkom kućanstva, *imaju veću sklonost potrošnji uslijed rasta dohotka.*

[3] Raspoloživi dohodak je onaj koji kućanstvu ostaje za potrošnju (C) i štednju (S) a izračunava se tako da se od ukupnog nacionalnog dohotka (NI) oduzmu neposredni porezi (Td) i pridodaju transferna plaćanja (Tp), dok raspoloživi dohodak na razini nacionalne ekonomije predstavlja BDP umanjen za poreze, štednju poduzeća, transferna plaćanja te plaćanja države za kamate.

Nasuprot navedenom, Loayza at el. (2000) koristeći široku bazu makroekonomskih podataka, *uočava značajniji utjecaj dohotka na štednju u manje razvijenim zemljama.* Ovakvu tvrdnju objašnjavaju s teorijom sklonosti potrošnje koja predviđa veći utjecaj dohotka prilikom niskih razina dohotka. Isto tako, *potvrđuje se značajno pozitivan utjecaj dohotka* na stopu privatne štednje koristeći sve statističke procjenitelje.

Grigoli at el. (2014) ispituju utjecaj ekonomskih determinanti na štednju putem kategorije razvijenosti zemalja i vremenskog perioda financijske krize. Isto tako, ispituju razlike između nacionalne, privatne, korporativne te štednje kućanstva. Navedeni autori dokazuju pozitivan utjecaj dohotka na privatnu štednju, kao i ostale kategorije štednje. Također, potvrđuju *relativno veću osjetljivost privatne štednje na rast dohotka razvijenijih u odnosu na nerazvijene zemlje.* Ovu tvrdnju potvrđuju Rocher i Stierle (2015) u svojoj studiji. Navedeni autori ne uočavaju konzistentnost s hipotezom permanentnog dohotka uvrštavanjem mjere stalnog i tranzitnog dohotka, naprotiv, studija uočava pozitivni doprinos *stalnog dohotka* na štednju dok je *tranzitorni dohodak* statistički neznačajan.

Loayza at el. (2000) u svojoj empirijskoj studiji *pozitivni* utjecaj stalnog dohotka objašnjava ograničenim vanjskim zaduživanju nerazvijenijih zemalja. Također, potvrđuje konzistentnost tranzitornog dohotka s teorijom permanentnog dohotka.

3.1.2. Inflacija

Inflacija je porast razine cijena u odnosu na prethodno razdoblje ili pad vrijednosti novca. Inflacija uzrokuje neizvjesnost, promjenu ponašanja pojedinca i gubitak povjerenja u novac što uzrokuje promjenu u strukturi štednje. S teorijskog stajališta, ističe se dvosmislen i nejasan utjecaj inflacije na štednju. Empirijske studije tradicionalno upotrebljavaju dvije mjere kojim ukazuju na značaj inflacije. To su indeks potrošačkih cijena CPI[4] koji mjeri promjenu cijena izabrane potrošačke košarice dobara i HICPs indikator.

Znanstvene studije ne slažu se u stavovima o važnosti i smjeru *utjecaja inflacije na štednju*. Muradoglu i Taskin (1996) navode argument intertemporarne potrošnje da očekivanja inflacije mogu poticati potrošnju roba široke potrošnje na *štetu štednje*.

Grigoli et al. (2014) ističu gubitak povjerenja pojedinca u financijske instrumente i institucije u situaciji makroekonomske, financijske i političke nestabilnosti uzrokovane i mjerene razinom

[4] CPI indikator se koristi za monetarne i ekonomske analize. Širok opseg upotrebe i korisnosti pruža, indeksacija komercijalnih ugovora, plaće, naknade socijalne zaštite, financijske instrumente...

inflacije, što *negativno* utječe na stopu štednje. Isto tako, Kukk i Staehr (2015) naglašavaju smanjenje duga poduzeća uslijed inflacije što može uzrokovati dodatno zaduživanje, odnosno *negativnu* povezanost inflacije i štednje. Kao posljedica navedenog, Ćurak i Mulač (2011) objašnjavaju važnost utvrđivanja razine inflacije s obzirom da umjerena inflacija ne utječe na povjerenje ljudi u novac, a galopirajuća dovodi do gubitka vrijednosti novca koja ljude potiče na zadržavanje minimalnih količina za transakcije.

Pozitivan utjecaj inflacije se objašnjava kroz pojam makroekonomske nesigurnosti i gubitka financijske imovine. Pojedinac prilikom visoke razine inflacije kao mjere makroekonomske nesigurnosti ima tendenciju *povećati razinu štednje iz predostrožnosti*. Isto tako, uslijed varijacije cijena, gospodarske nesigurnosti, poduzeća otežano planiraju buduće investicije, što uzrokuje *porast štednje.* Dodatno, visoke stope inflacije utječu na dohodak. Mirovine koje nisu u skladu sa varijacijom cijena, gube na nominalnoj vrijednosti kao i radnici prilikom dobivanja plaća ukoliko *cijene i nadnice ne rastu proporcionalno.* Navedena situaciju stavlja pojedinca u položaj gubitka financijske imovine uslijed čega iz psiholoških motiva nadoknade izgubljenog *povećavaju stopu štednje.*

Empirijskim istraživanjem Muradoglu i Taskin (1996) dokazuju *negativan utjecaj inflacije* za industrijske zemlje. Kućanstva uslijed pretpostavke rasta nominalnog dohotka povećavaju tekuću potrošnju. S druge strane, Grigoli at el. (2014) potvrđuju da nad promatranim skupom zemalja inflacija stvara *značajan pozitivan utjecaj na stopu štednje* za sve promatrane kategorije uz iznimku pojedinih procjenitelja. Navedeni autori proširuju pretpostavku *pozitivnog utjecaja inflacije* kroz efekt veće trenutne cijene dobara što odgađa potrošnju, a povećava stopu štednje. Pored navedenih objašnjenja za brojna nekozinstentna empirijska saznanja, uočavaju se različiti pristupi u metodologiji utvrđivanja i prikupljanja podataka što u značajnoj mjeri doprinosi različitim logičkim interpretacijama.

Statistički neznačajan utjecaj inflacije na dohodak za zemlje u razvoju objašnjava se „sposobnošću brze prilagodbe kućanstava tih zemalja s obzirom na kontinuiranu izloženost visokim stopama inflacije što uvjetuje i smanjenu stopu novčane iluzije“, (Muradoglu i Taskin, 1996, str. 148).

Rocher i Stierle (2015) provode istraživanje nad zemljama Europske unije, a kao mjeru inflacije koriste HICP[5]s indikator. Dokazuju *pozitivnu povezanost inflacije i stope štednje*.

Kukk i Staehr (2015) objašnjavaju mogućnost *negativnog utjecaja indireknim kanalom*, tj. uslijed visoke stope inflacije navode smanjenje korporativnog duga (inflatorne dobitke s obzirom da su korporacije neto dužnici) što otvara kapacitet novog zaduživanja i smanjene stope štednje. Potvrđuju *negativnu povezanost inflacije i korporativne štednje*, dok za sektor kućanstva dokazuju *značajnu pozitivnu povezanost,* što potvrđuje i razvijeni model od Hüfner i Koske (2010).

3.1.3. Nezaposlenost

Nezaposlenost je položaj u kojemu dio radno sposobnih članova društva ne može ostvariti temeljni dohodak svojim radom. Utjecaj nezaposlenosti na štednju može biti i pozitivan i negativan.

Nezaposlenost se u empirijskim analizama koristi kao mjera makroekonomske nesigurnosti. Promatrane empirijske studije objašnjavaju *pozitivan utjecaj* varijable 'nezaposlenost' na štednju iz predostrožnosti od gubitka radnih mjesta i dohotka u budućnosti. Uslijed visoke stope nezaposlenosti, pojedinac osjeća strah od gubitka radnog mjesta i tekućeg dohotka, što je *motiv za štednju* svakog pojedinca.

Isto tako, naglašava se *negativan utjecaj* na dohodak i štednju uslijed visoke razine nezaposlenosti, dohodak se smanjuje što uvjetuje *smanjenje raspoloživih sredstava za štednju.* „Osnovni uvjet koji osigurava izvore prihoda pojedincu, materijalni status, ali i sudjelovanje i ponašanje u potrošnji jednom pojedincu jest njegov radni angažman“, (Pojatina, 1981, str. 47). Izostajanjem tekućeg dohotka, smanjuje se mogućnost zadovoljavanja egzistencijalnih, društvenih i luksuznih potreba. Iz navedenog, uslijed povećane stope nezaposlenosti pretpostavlja se *negativan utjecaj na stopu štednje.*

Rocher i Stierle (2015) empirijski dokazuju *pozitivan doprinos nezaposlenosti na štednju*, dok istraživanja Kukk i Staehr (2015) i Schrooten i Stephan (2004) na grupi europskih zemalja potvrđuju *statističku neznačajnost utjecaja nezaposlenosti na štednju*.

[5] Prema izvještaju Europske komisije, razlika između HICPs i CPI indikatora može biti u ciljevima, konceptima i metodama rada. ECB koristi usklađeni HICPs indikator za svrhu monetarne politike. Također se navodi kao jedini komparabilan indikator za zemlje Europske unije.

3.1.4. Kamatna stopa

Teorija pretpostavlja *pozitivan* utjecaj kamatne stope na štednju objašnjavajući kamatu kao nagradu za odricanje od likvidnosti. Rast kamatne stope utječe na *povećanje* štednje, odnosno spremnost pojedinca na odlaganje novca. U nedostatku podataka o realnoj kamatnoj stopi koristi se kamatna stopa na depozite.

Dokazi o utjecaju kamatne stope u empirijskim studijama su ograničeni. Muradoglu i Taskin (1996) objašnjavaju dva pristupa; argument intertemporarne potrošnje koji pretpostavlja *pozitivan doprinos kamatne stope na štednju* te navode dokaze Balassa (1992) o *pozitivnom* utjecaju u razvijenim zemljama i Koskela i Viren (1982) koji potvrđuju *pozitivan* utjecaj za industrijske zemlje. Drugi pristup objašnjavaju efektom inflacije uz uvjet konstantne nominalne kamatne stope, inflacija djeluje na smanjen trošak zaduživanja. Navedena pretpostavka uzrokuje povećanje potrošnje i *smanjenu stopu štednje*. Isti autori pronalaze *negativnu povezanost na uzorku industrijskih zemalja,* dok utjecaj kamatne stope ne pokazuje povezanost sa štednjom u objašnjenju za zemlje u razvoju.

3.2. Demografski čimbenici

3.2.1. Broj o hranitelju obitelji ovisnih članova

Teorijska promišljanja naglašavaju važnost broja ovisnih članova u procesu donošenja odluke o štednji. Razvijeni modeli ekonomskih studija uočavaju dvosmislenost utjecaja; može biti i pozitivan i negativan.

U kontekstu većeg broja ovisnih članova u obitelji pretpostavlja se veća proporcija potrošnje s obzirom da hranitelj ima potrebu i obvezu brige o ovisnim članovima obitelji. U kategoriju ovisnih članova ubrajaju se skupina mladog stanovništva (0-14) te starije populacije (65+).

Nasuprot navedenom, brojni motivi poput predostrožnosti i brige za budućnost, obitelj sa ovisnim članovima (prvenstveno djecom) daju poticaj štednji za slučaj nepredviđenih situacija i osiguranja bolje budućnosti djeci.

Muradoglu i Taskin (1996) proučavaju utjecaj ovisnih članova na štednju za zemlje u razvoju odvojene od industrijskih zemalja. Istraživanje pokazuje *negativan utjecaj* ovisnih članova za zemlje u razvoju dok je parametar statistički neznačajan za industrijske zemlje. Autori objašnjavaju rezultat kao posljedicu stabilne situacije u industrijskim zemljama gdje je proporcija ovisnih skupina manja u odnosu na zemlje u razvoju. Zemlje koje se razvijaju određene su sa većim stopama nataliteta te se dobna struktura brzo mijenja. Stoga, kako se

ovisne skupine pojedinog društva smanjuju, *povećava se stopa štednje* kao supstitut potrošnje na djecu.

Grigoli at el. (2014) ističu teoriju životnog ciklusa u kontekstu objašnjenja utjecaja ovisnih članova na stopu štednje. Empirijskim istraživanjem potvrđuju dokaz Loayza at el. (2000) o *negativnom utjecaju ovisnih članova na stopu štednje*. Što je veći udio mlađe i starije dobne skupine u odnosu na radno aktivnu kategoriju stanovništva, *stopa štednje će biti manja*.

3.2.2. Urbanizacija

Urbanizacija je proces širenja gradskog stanovništva, koncentracije i integracije društva te transformacije djelatnosti koja rezultira socioekonomskom promjenama. Pretpostavlja se *negativan utjecaj urbanizacije na razinu štednje*. Tvrdnja se objašnjava kroz mogućnosti pojedinca u obliku potrošnje, razvijenijeg društvenog života, stabilnog dohotka uslijed kojeg nema motiva štedjeti zbog predostrožnosti. Teorija pretpostavlja da *urbano stanovništvo štedi manje u odnosu na ruralno stanovništvo* koje je obilježeno nesigurnim dohotkom, manjom zastupljenošću kreditnih prilika što utječe na veće stope štednje.

Loayza at el. (2000) dokazuju *negativan utjecaj urbanizacije na stopu štednje.* Grigoli at el. (2014) potvrđuju *negativan* utjecaj urbanizacije te naglašavaju utjecaj gradskih mogućnosti na povećanu potrošnju. Nadalje, ovakav smjer isti autori objašnjavaju kroz štednju iz predostrožnosti ruralnog stanovništva uslijed nemogućnosti planiranja sigurnog dohotka.

Pored objašnjenih demografskih determinanti, Niculescu-Aron i Mihăescu (2012) empirijski potvrđuju *pozitivan* utjecaj demografske mjere ***očekivano trajanje života*** na štednju u zemljama zapadne Europe uz iznimku Italije, Španjolske i Portugala. Testiranjem modela na zemljama istočne i srednje Europe kao i grupe zemalja EU dokazuje se *statistički neznačajan utjecaj* životnog vijeka pojedinca na štednju. Ovo istraživanje je u skladu sa rezultatima Rocher i Stierle (2015) koji su dokazali *statistički neznačajan utjecaj* očekivanog trajanja života na štednju nad grupom zemalja EU.

3.3. Ostali specifični čimbenici

Schrooten i Stephan (2004) razvijaju model u kojem provode ispitivanje o utjecaju ***fiskalne i monetarne politike u zemljama EU.*** Dokazuju *značajno negativan utjecaj* fiskalne politike na stopu štednje, dok monetarna politika *nema značajan utjecaj*. Utjecaj fiskalne politike objašnjavaju *kroz ponašanje prema štednji*. Zaključuju da štednja javnog sektora značajno *smanjuje privatnu štednju*, u kratkom i dugom roku. Navedene interpretacije autora su u skladu

sa rezultatima koje su dobili Serres i Pelgrin (2003) u istraživanju utjecaja determinanti na stopu štednje u OECD zemljama tijekom 1990-ih godina. Naglašavaju značajan utjecaj štednje javnog sektora, te dokazuju *negativnu povezanost javne i privatne štednje.* S druge strane, Rocher i Stierle (2015), Kukk i Staehr (2015) koriste ***'proračunski saldo države'*** kao mjeru fiskalne politike. U skladu sa 'Ricardian equivalence hypothesis' dokazuju *negativan* utjecaj štednju. Ukoliko proračunski deficit raste, pojedinci su skloniji većoj proporciji štednje od potrošnje kao rezultat manjih poreza ili povećane državne potrošnje.

Nadalje, Schrooten i Stephan (2004) uočavaju povezanost privatne štednje i ***učinkovitosti financijskog sektora.*** Pretpostavka se temelji na koncentriranosti bankarskog sektora u zemljama EU, a kao mjeru učinkovitosti koriste omjer M2/GDP. Testiranje rezultira *pozitivnim doprinosom* učinkovitosti financijskog sektora na stopu privatne štednje, dok mjera udio privatnih kredita u BDP-u ukazuje na beznačajan utjecaj.

Loayza at el. (2000) dokazuju značajno *negativan utjecaj kretanja* ***domaćih kredita privatnom sektoru*** u odnosu na dohodak, što ukazuje da otpuštanje kreditnih ograničenja, dovodi do *smanjenja* štednje. Prema autorima, ovaj koeficijent je znatno manji kod razvijenih zemalja zbog neobvezujućih kreditnih ograničenja pa smanjenje ograničenja ne dovodi do bolje dostupnosti kredita. Hüfner i Koske (2010) kao mjeru financijskog razvoja koriste ***'likvidne obveze banaka i drugih financijskih posrednika',*** umjesto kretanja domaćih kredita privatnom sektoru. Istraživanje provode nad grupom zemalja G7 te *dokazuju statističku neznačajnost* ovog čimbenika uz iznimku *značajno negativnog utjecaja za Francusku*. Razliku u interpretaciji rezultata i upotrebu ove mjere u odnosu na Loayza at el. (2000) objašnjavaju dostupnošću podataka te efektom mjere domaćih kredita privatnom sektoru koji mogu odražavati veće zaduživanje stanovništva kroz učinak bogatstva.

Lovrinčević at el. (2005) testiraju utjecaj bruto priljeva inozemnog kapitala na domaće investicije i stopu štednje. Bruto priljev razgraničavaju na tri komponente; ***izravne strane investicije, portfolio investicije*** te ***ostale inozemne investicije*** (inozemni krediti). Pitanje koje se postavlja je *učinak ograničenja inozemnog financiranja* ukoliko su nacionalna i inozemna štednja supstituti.[6] Autori dokazuju *negativan utjecaj komponenti inozemnog kapitala na nacionalnu štednju, ali statistički neznačajan.* Navedena interpretacija rezultira *da nacionalna i inozemna štednja nisu supstituti.* S druge strane, Kukk i Staehr (2015) dokazuju supstituciju

[6] Ukoliko nacionalna i inozemna štednja nisu supstituti tada ograničenja inzozemnog financiranja dovode do pada domaćih investicija, time gospodarskog pada, a naposljetku i domaće štednje bez direktnog kanala utjecaja.

inozemnog financiranja i korporativne štednje. Snažnija je *pozitivna povezanost* s štednjom korporacija u odnosu na kućanstvo zbog lakše dostupnosti inozemnih sredstava.

Nasuprot navedenom, Rocher i Stierle (2015) koriste ***izravna strana ulaganja kao pokazatelj međunarodne financijske integriranosti*** koja nejasno definira svoj utjecaj. Bolja financijska integriranost, deregulacija, financijska globalizacija omogućuju lakšu dostupnost sredstava. Uslijed gospodarskog rasta, ekonomske ekspanzije i investicija, dostupnost sredstava smanjuje stopu štednje kućanstva. S druge strane, integriranost financijskog tržišta pruža različite mogućnosti ulaganja i štednje. Istraživanje dokazuje *negativan utjecaj na štednju.*

Grigoli at el. (2014) proučavaju utjecaj čimbenika ***'uvjeti poslovanja'*** na štednju. Smatraju da povećanje uvjeta poslovanja poboljšava izvoznu poziciju uslijed koje direktni priljev novca iz inozemstva pozitivno utječe na dohodak. Uslijed povećanja dohotka priljevom novca iz inozemstva, pretpostavka autora je veća proporcija štednje. Empirijskim istraživanjem dokazuju neznatan *pozitivan učinak 'uvjeta poslovanja'*, dok Rocher i Stierle (2015) uočavaju *negativan utjecaj na štednju*. Kao razlog ističu povećanje kupovne moći, uslijed boljih uvjeta poslovanja, koja rezultira povećanom potrošnjom.

3.4. Financijska kriza

Globalna ekonomska kriza *značajno je utjecala* na gospodarsku aktivnost.

Koncept temeljen na deregulaciji i snažnom priljevu inozemnog kapitala omogućio je kreditnu ekspanziju, povećanje vrijednosti nekretnina i ekstreman rast potrošnje što je utjecalo na rast gospodarstva i zaposlenosti. Posljedice nekontrolirane ekspanzije istaknuli su dramatične ekonomske probleme; kolaps financijskih institucija, nedovoljna ponuda kredita, ekstremno smanjenje vrijednosti imovine i drastično povećanje stope nezaposlenosti. Buti at el. (2009) objašnjava tri bitna prijenosna kanala financijske krize na gospodarstvo promatranih članica EU: kordinacija financijskog sustava (u procesu razduživanja, banke su smanjile izloženost tržištima u nastajanju), smanjene vrijednosti bogatstva (nepovoljno se odrazilo na financijska tržišta), te putem globalne trgovine (izbijanjem krize nastao je kolaps svjetske trgovine).

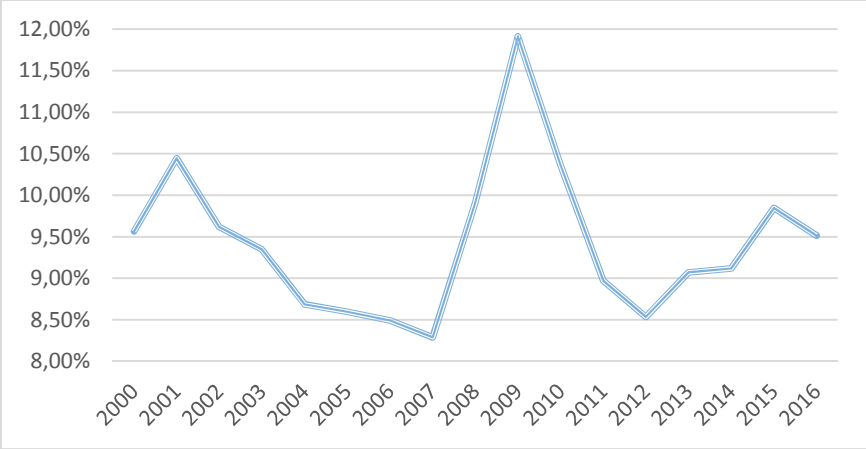
Nadalje, ekonomska i financijska nestabilnost tijekom globalne recesije utjecala je na sklonost štednji, tj. kriza je *pozitivno doprinijela povećanju štednje* kućanstva. Ova tvrdnja objašnjava se motivima *štednje iz predostrožnosti* uslijed nesigurnog budućeg dohotka i straha od gubitka radnog mjesta pod utjecajem visoke stope nezaposlenosti, inflacije i pada tekućeg dohotka.

Potvrdu navedenih teorija obogaćuju empirijske studije, a izdvajaju se Kamakura i Du (2012) kroz objašnjenje *smanjenja proporcija potrošnje* tijekom razdoblja globalne recesije. Isto tako, ističu pad raspoloživog dohotka kao posljedicu povećanja nezaposlenosti, niže stope povrata na investicije i smanjenje plaća. S druge strane, navode sklonost pojedinca štednji i otplati dugova. Laitamäki i Järvinen (2013) navode Pantzar i Kytö (2010) koji uočavaju odgađanje potrošnje na nekretnine i brodove pojedinca početkom recesije.

Također, *značajan doprinos krize* na pojedine determinante štednje *potvrđuje* Grigoli at el. (2014) provođenjem empirijskog istraživanja. Pokazuju primjetan *pad utjecaja dohotka* na štednju kao i *smanjenje negativnog efekta urbanizacije* na štednju. Nadalje, empirijska studija Kukk i Staehr (2015) nad deset promatranih članicama Istočne i Srednje Europe dokazuje da poslovni ciklus nema doprinos na ukupnu štednju kućanstva, čak ni u scenariju globalne recesije uslijed rasta štednje stanovništva. U konačnici, procjenjivanjem modela za predkrizno razdoblje u odnosu na cjelokupan period 1997.-2012. godine, zaključuju: da je *globalna kriza promijenila štednju stanovništva*. Na kraju, autori navode istraživanje EBRD (2011) koje *potvrđuje utjecaj globalne krize na potrošnju i štednju kućanstva* u zemljama Srednje i Istočne Europe.

4. ANALIZA ŠTEDNJE U IZABRANIM ČLANICAMA EU

Analiza štednje promatranih zemalja, članica EU u ovom istraživanju pružiti će grafički pregled kretanja štednje stanovništva, te promjene tijekom razdoblja globalne krize. Odabrane jedinice promatranja, članice EU, nad kojim se provodi analiza su: Češka, Danska, Estonija, Finska, Njemačka, Mađarska, Italija, Latvija, Španjolska, Poljska, Portugal, Slovenija i Švedska. Promatrano razdoblje obuhvaća vremenski period od 2000. do 2016. godine.

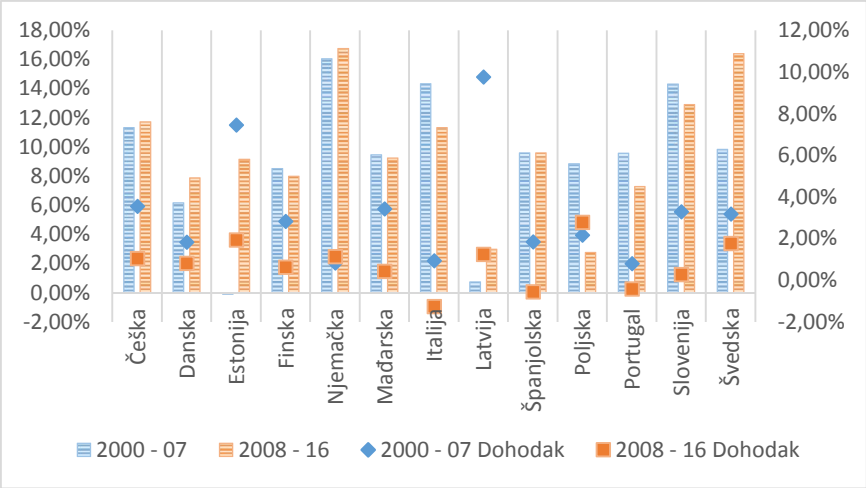


Graf 1: Prosječna štednja kućanstva

Izvor: rad autora prema podacima: http://ec.europa.eu/eurostat/data/database, (29.9.2017)

Trend štednje promatranih članica je *relativno stabilan,* za razdoblje 2000.-2016. godine, osim za razdoblje *globalne financijske krize*. U periodu *prije globalne krize* sklonost stanovništva štednji bila je od 8% do 10,5% raspoloživog dohotka, a posljednje dvije godine prije krize štednja je stabilna (graf 1). Posljedica *globalne krize* je *pozitivan doprinos* na štednju stanovništva tijekom razdoblja 2008.-2010. (graf 1). Ističe se povećanje sa 8% na 12% raspoloživog dohotka (graf 1), uz *značajan pad* raspoloživog dohotka po glavi stanovnika (graf 2). Nakon gospodarskog oporavka 2010. godine, štednja stanovništva *se smanjuje* (graf 1), te se uočava *stabilizacija štednje* na razine istaknute u predkriznom razdoblju.

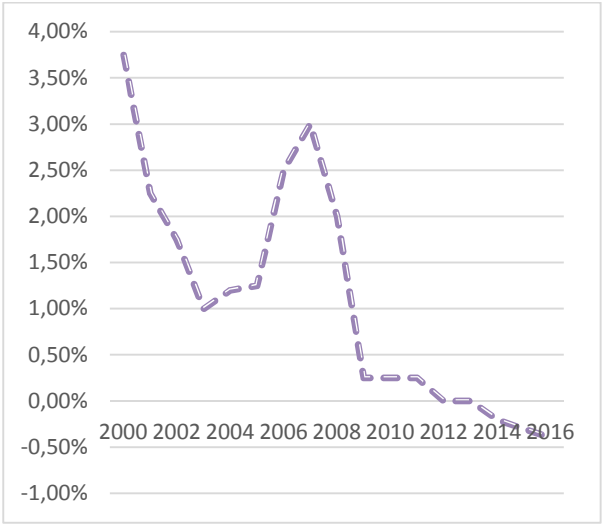
Nadalje, pregled razine štednje između promatranih članica potvrđuje značajna odstupanja udjela štednje u dohotku (graf 2). Primjerice, *značajna sklonost štednji* u rasponu 11% do 16% raspoloživog dohotka uočava se za kućanstva Njemačke, Italije, Slovenije i Češke, dok Latvija i Poljska imaju najmanju stopu štednje od 2,8% raspoloživog dohotka. U ovom kontekstu, razina štednje promatra se kao indikator *dostupnih kredita za financiranje realnog sektora, sredstava za investicije i gospodarskog rasta,* (Rocher i Stierle, 2015, str. 5). Stoga, određene zemlje u većoj mjeri koriste inozemna zaduživanja što povećava osjetljivost na vanjske šokove.



Graf 2: Štednja kućanstva

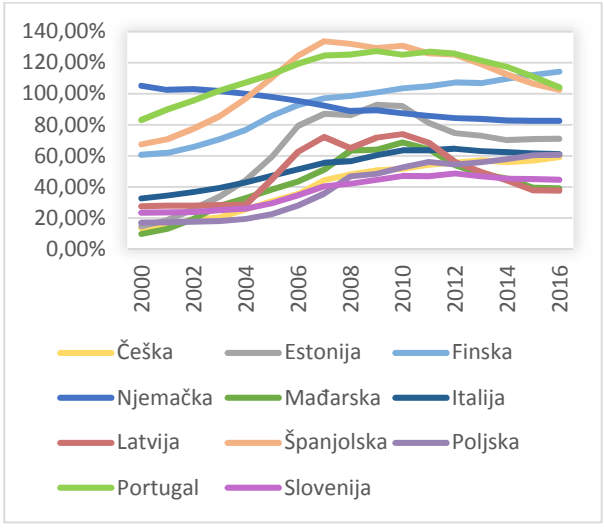
Izvor: rad autora prema podacima: http://ec.europa.eu/eurostat/data/database, (29.9.2017)

Trend blagog pada štednje *prije globalne krize* posljedica je financijske deregulacije, smanjenja kamatnih stopa (graf 3) i rasta bogatstva. Isto tako, pored navedenog, Hartstein (2013) ističe značajan doprinos tehnološke revolucije, uz deregulaciju, na *smanjenje štednje kućanstva* zbog mogućnosti lakšeg pristupa kreditima. Doprinos navedene tvrdnje ukazuje grafikon 4. Trend *rasta bruto duga* do 2008. godine obuvaća sve promatrane članice osim Njemačke koja bilježi pad zaduživanja stanovništva za 16,20%. Značajan *rast zaduženosti* u 2008. godini ističe se kod Estonije sa 71,56%, Mađarske 53,80% i Španjolske 64,79% u odnosu na 2000. godinu (graf 4).



Graf 3: Kamatna stopa na depozite

Izvor: rad autora prema podacima: http://ec.europa.eu/eurostat/data/database, (29.9.2017)

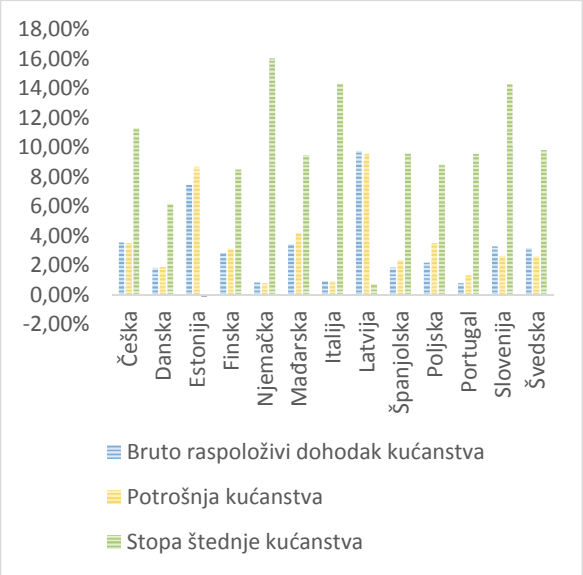


Graf 4: Omjer bruto duga i dohotka

Izvor: rad autora prema podacima: http://ec.europa.eu/eurostat/data/database, (29.9.2017)

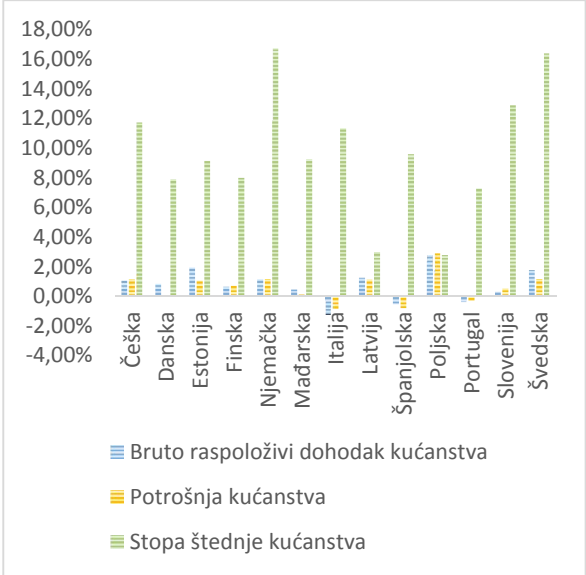
Nadalje, naglašava se uloga *povećanja cijene nekretnina* koja se koristi kao kolateral prilikom zaduživanja. Rast vrijednosti nekretnina *značajno je utjecao na smanjenje štednje*.

Nasuprot navedenom, pojava *globalne krize* snažno je utjecala na *sklonost štednji* kućanstva promatranih članica EU. Od početka krize, kućanstva se suočavaju sa uvjetima visokog stupnja nesigurnosti, straha od gubitka radnog mjesta i budućeg dohotka. Navedena tvrdnja doprinosi *povećanju štednje iz predostrožnosti* kao osiguranje od neočekivanih troškova. Intezitet ovisi o averziji prema riziku pojedinca i kreditnoj sposobnosti kako bi osigurali financiranje potrošnje. Isto tako, scenarij snažnog pada vrijednosti dionica i druge imovine doprinosi *štednji* kao motiv obnove bogatstva. Prema tome, kriza je drastično smanjila dohodak i potrošnju kućanstva (graf 5 i 6). Značajno smanjenje potrošnje ostvarila su kućanstva Latvije (-8,46%), Estonije (-7,64%), Španjolske (-3,14%) u odnosu na predkrizno razdoblje (graf 5 i 6).



Graf 5: Raspoloživi dohodak i podjela po krajnjoj upotrebi, razdoblje 2000. – 2007. godine

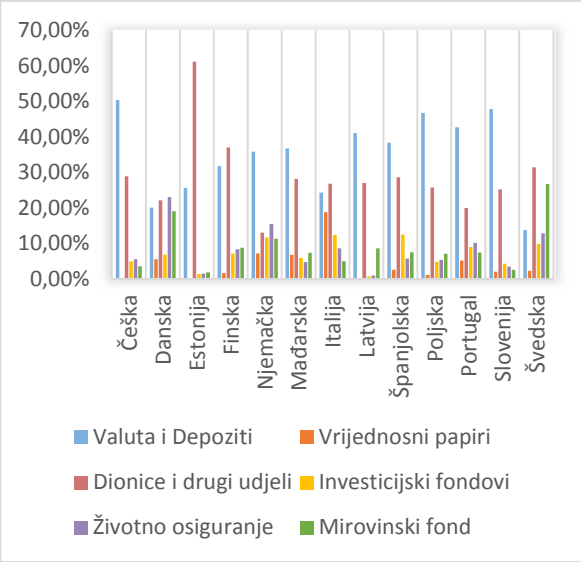
Izvor: rad autora prema podacima: http://ec.europa.eu/eurostat/data/database, (29.9.2017)



Graf 6: Raspoloživi dohodak i podjela po krajnjoj upotrebi, razdoblje 2008. – 2016. godine

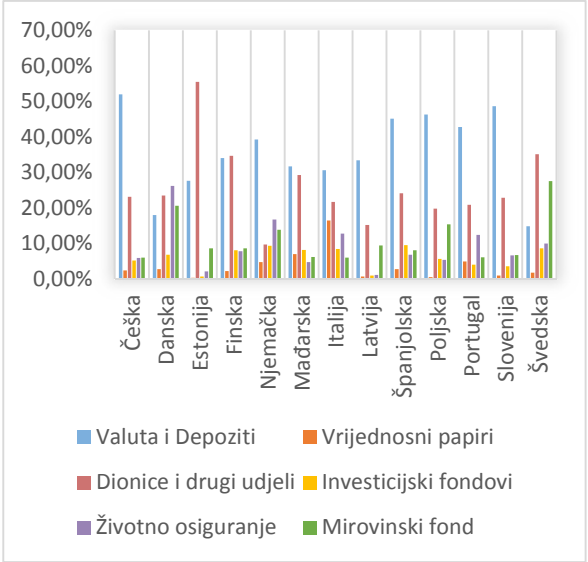
Izvor: rad autora prema podacima: http://ec.europa.eu/eurostat/data/database, (29.9.2017)

Stanovništvo promatranih članica EU koristi tradicionalni pristup ulaganja financijske imovine putem bankarskih depozita, osim Danske, Estonije, Finske i Švedske u kojima je značajno ulaganje na tržištu kapitala. Štednja u obliku gotovine i depozita predstavlja *najsigurniji instrument ulaganja*. Prosječna sklonost ulaganja u depozite čini 35%, a ističu se Češka (51,98), Poljska (46,26), Španjolska (45,09) i Slovenija (48,66). Palenzuela et al. (2016) smatraju da prikazani trend upućuje na nerazumijevanje financijskih proizvoda i mogućnosti, dok primjetnu manju sklonost ulaganja putem mirovinskih fondova i društva za osiguranje navode kao posljedicu starijeg stanovništva tj. da mlađe osobe imaju veću sklonost ugovaranju životnog osiguranja.



Graf 7: Financijska imovina kućanstva, 2000. – 07

Izvor: rad autora prema podacima: http://ec.europa.eu/eurostat/data/database, (29.9.2017)

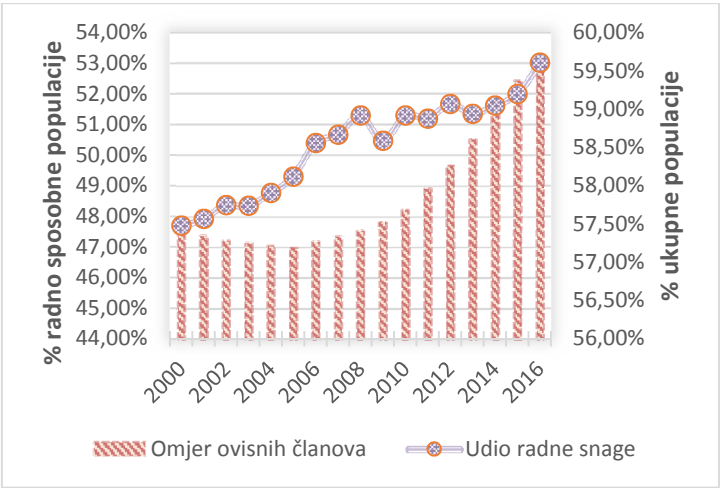


Graf 8: Financijska imovina kućanstva, 2008. – 16

Izvor: rad autora prema podacima: http://ec.europa.eu/eurostat/data/database, (29.9.2017)

Primjetan je *porast* ugovaranja životnog osiguranja, posebno kod Danske, Italije i Slovenije, dok se značajan rast mirovinskih fondova uočava za Češku, Poljsku, Estoniju, Njemačku i Sloveniju (graf 7 i 8).

Starenje stanovništva snažno utječe na kretanje štednje. Uočava se trend rasta radne snage, ali u manjoj mjeri od rasta ovisnih članova obitelji. Posljedica neproporcionalnog rasta je *smanjenje* štednje stanovništva kroz dugi vremenski period (graf 9). S obzirom na starenje stanovništva promatranih članica što upućuje na stalni rast udjela ovisnih članova, članice EU, zakonskom regulativom produžavanja radnog vijeka pojedinca nastoje ublažiti pad štednje.



Graf 9: Demografska struktura

Izvor: rad autora prema podacima: http://ec.europa.eu/eurostat/data/database, (29.9.2017)

5. EMPIRIJSKO ISPITIVANJE VAŽNOSTI UTJECAJA EKONOMSKIH I DEMOGRAFSKIH DETERMINANTI ŠTEDNJE

5.1. Podaci i metodologija

Za potrebe istraživanja utjecaja ekonomskih i demografskih determinanti na potencijal štednje provodi se empirijsko istraživanje pomoću odabranih procjenitelja dinamičkih panel modela. Odabrane jedinice promatranja, članice EU, nad kojim se provodi panel analiza su: Češka, Danska, Estonija, Finska, Njemačka, Mađarska, Italija, Latvija, Španjolska, Poljska, Portugal, Slovenija i Švedska. Promatrano razdoblje obuhvaća vremenski period od 2000. do 2016. godine te se ispituje utjecaj ekonomskih determinanti (*dohodak, inflacija, kamatne stope i nezaposlenosti*) i demografskih determinanti (*o hranitelju obitelji ovisne skupine i stupanj urbanizacije*) na štednju. Korišteni podaci u empirijskom ispitivanju nazivaju se nebalansirani panel podaci, s obzirom da za određene jedinice promatranja nedostaje podataka za varijablu 'kamatna stopa'. Prilikom istraživanja vremenske i prostorne komponente koristi se panel analiza, putem koje je omogućeno analiziranje više jedinica promatranja istovremeno. Ispitivanje utjecaja korištenjem panel analize pružaju se precizniji rezultati s obzirom da se zavisna varijabla (štednja) mijenja po jedinici promatranja (države) i po vremenu (godine), (Škrabić Perić, 2015). Promatrano razdoblje obuhvaća period *globalne krize*, stoga se odvojeno razmatra promjena utjecaja odabranih determinanti na štednju stanovništva za razdoblje 2008.-2010. Kategorija ekonomskih i demografskih varijabli koje će se koristiti u istraživanju su:

Tablica 1: Varijable, mjere varijabli i očekivani predznak utjecaja

Varijabla	*Mjera varijable*	*Kratica*	*Očekivani predznak*
Dohodak	BDP po glavi stanovnika, rast (godišnje %)	gdp	+
Inflacija	BDP deflator (godišnje %)	inf	+/-
Kamatna stopa	Realna kamatna stopa (%)	ir	+/-
Nezaposlenost	Nezaposlenost, ukupno (% od ukupne radne snage)	unp	+/-
O hranitelju obitelji ovisne skupine 1	Starije ovisne skupine (% uk. populacije.)	ado	+/-
O hranitelju obitelji ovisne skupine 2	Mlađe ovisne skupine (% uk. populacije.)	ady	+/-
Stupanj urbanizacije	Urbana populacija (% od ukupne)	up	-
Kriza	Dummy varijabla	kriza	-

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Na temelju pregledane literature i dostupnih podataka koriste se navedene determinante u svrhu razvijanja modela. Korišteni podaci prikupljeni su s web-stranice Svjetske banke, baza podataka; World Development Indicators.

Nezavisne varijable čiji se utjecaj na štednju ispituje u ovom empirijskom istraživanju su: *BDP po glavi stanovnika* (gdp), *inflacija* (inf), *kamatna stopa* (ir), *nezaposlenost* (unp), *o hranitelju obitelji ovisne skupine: starija populacija* (ado), *mlađa populacija* (ady) i *stupanj urbanizacije*.

$$GDS_{it} = \mu + \gamma GDS_{i,t-1} + \beta_1 GDP_{it} + \beta_2 INF_{it} + \beta_3 IR_{it} + \beta_4 UNP_{it} + \beta_5 ADO_{it} + \beta_6 ADY_{it} + \beta_7 UP_{it} + \alpha_i + \varepsilon_{it}; i = 1,...N, t = 1,..., T,$$

Pri čemu je:

N *- broj jedinica promatranja, ukupno ima 13 zemalja Europske unije,*
T *- broj razdoblja, promatrani razdoblje predstavlja interval od 17 godina, od 2000.god. – 2016.god.,*
α *- konstantni član primijenjenog modela, jednak za sve jedinice promatranja i ne mijenja se kroz vrijeme,*
μ *- konstantni član*
GDS_{it} *- pokazatelj bruto domaće štednje u zemlji i, u razdoblju t,*
GDP_{it} *- pokazatelj BDP-a po glavi stanovnika u zemlji i, u razdoblju t,*
INF_{it} *- pokazatelj stope inflacije u zemlji i, u razdoblju t,*
IR_{it} *- pokazatelj kamatne stope u zemlji i, u razdoblju t,*
UNP_{it} *- pokazatelj stupnja nezaposlenosti u zemlji i, u razdoblju t,*
ADO_{it} *- pokazatelj o hranitelju obitelji ovisne skupine 1, starija populacija, u radno aktivnoj kategoriji u zemlji i, u razdoblju t,*
ADY_{it} *- pokazatelj o hranitelju obitelji ovisne skupine 2, mlađa populacija, u radno aktivnoj kategoriji u zemlji i, u razdoblju t,*
UP_{it} *- pokazatelj stupnja urbanizacije u ukupnoj populaciji u zemlji i, u razdoblju t,*
ε_{it} *- greška relacije zemlje i, u razdoblju t, pretpostavlja se da su* ε_{it} *nezavisno i identično distribuirane slučajne varijable po jedinicama promatranja i vremenu, sa sredinom 0 i varijancom* σ_ε^2,
γ *- parametar uz zavisnu varijablu s pomakom koje treba procijeniti,*
$\beta_1,..., \beta_K$ *- parametri koji se nalaze uz nezavisne varijable i koje treba procijeniti,*
Pretpostavlja se da su svi x_{itk} *nezavisni sa* ε_{it} *za sve i, t, k.*

Navedena ekonomska relacija je dinamičke prirode, stoga sadašnja vrijednost zavisne varijable (štednja stanovništva) ovisi o njezinim vrijednostima iz prethodnog razdoblja. Dinamički panel modeli sadržavaju zavisnu varijablu s pomakom za jedan ili više vremenskih perioda unatrag ovisno o svojstvima zavisne varijable tj. za ovu relaciju koristimo pojam autoregresije. Kretanje razine štednje određeno je brojnim motivima i determinantama kroz duže vremensko razdoblje, prema tome utjecaj navedenih varijabli na sklonost štednji se uočava nakon određenog perioda.

Prema podacima deskriptivne statistike (tablica 2) prosječna vrijednost udjela bruto štednje u BDP-u koja iznosi *24.40857* % BDP-a. Navedena srednja vrijednost pokazuje značajno stabilan prosječni udio štednje što potvrđuje i istraživanje Grigoli at el. (2014). Isto tako, *ne uočava se snažna disperziranost podataka*, odnosno odstupanje vrijednosti zavise varijable od prosječne vrijednost. Standardna devijacija je „pozitivni korijen iz varijance i predstavlja apsolutnu mjeru disperzije u prvom stupnju“ (Rozga, 2006., str. 58), tj. ukazuje na raspršenost varijable.

Tablica 2: Deskriptivna statistika zavisnih i nezavisnih varijabli

```
. xtsum gds gdp inf ir ado ady up unp
```

Variable		Mean	Std. Dev.	Min	Max	Observations
gds	overall	24.40857	4.768461	13.52235	34.57935	N = 208
	between		4.44294	15.56627	31.12182	n = 13
	within		2.104501	18.09447	31.15161	T = 16
gdp	overall	1.994903	3.783542	-14.55984	12.92044	N = 208
	between		1.630939	-.158928	5.259871	n = 13
	within		3.442089	-16.87145	9.655472	T = 16
inf	overall	2.676759	2.782819	-9.75288	20.14865	N = 208
	between		1.314847	1.176974	5.048057	n = 13
	within		2.478011	-12.12418	17.77735	T = 16
ir	overall	3.886962	3.990006	-7.69004	28.79081	N = 115
	between		2.255675	1.021492	8.994371	n = 12
	within		3.63188	-7.336915	29.14394	T = 9.58333
ado	overall	25.37195	3.614954	17.93453	35.08135	N = 208
	between		3.023414	19.25177	30.47824	n = 13
	within		2.142255	19.96533	32.11925	T = 16
ady	overall	23.03819	2.445887	19.56146	28.66225	N = 208
	between		2.256478	20.72113	27.63109	n = 13
	within		1.122335	20.97632	28.5739	T = 16
up	overall	70.91629	10.25119	49.65	87.676	N = 208
	between		10.57868	50.25775	86.32562	n = 13
	within		1.134787	66.30029	75.36929	T = 16
unp	overall	9.243033	4.169291	3.43	26.09	N = 211
	between		2.915192	5.528235	15.93294	n = 13
	within		3.055166	1.540092	19.40009	T = 16.2308

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Standardna devijacija iznosi 4,768461 postotnih poena, dok prema koeficijentu varijacije[7] koji iznosi 19.536% *ne postoji snažnija disperziranost štednje*, tj. značajnije odstupanje vrijednosti zavise varijable od njezine prosječne vrijednost.

$$V = \frac{\sigma}{\overline{X}} * 100 \text{ , } \sigma = 4{,}768461, \ \overline{X} = 24.40857$$

Pregled tablice 3 uočava minimalnu vrijednost štednje od *13.52235% BDP-a za Portugal*, dok je maksimalna vrijednost od *34.57935% BDP-a kod Češke.*

Tablica 3: Deskriptivna statistika zavisne varijable po zemljama

```
-> zemljaid = 11
```

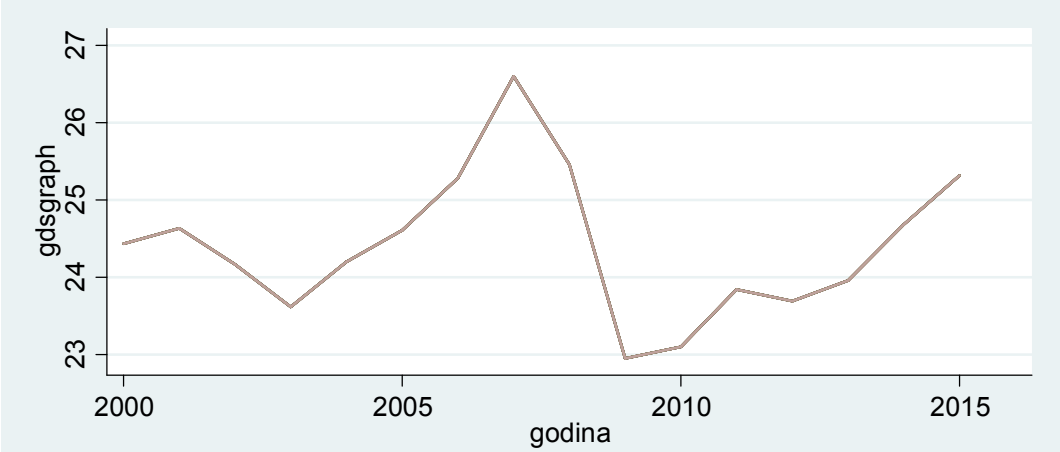
Variable	Obs	Mean	Std. Dev.	Min	Max
gds	16	15.56627	1.40809	13.52235	17.9267

```
-> zemljaid = 1
```

Variable	Obs	Mean	Std. Dev.	Min	Max
gds	16	31.12182	1.767205	27.96221	34.57935

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

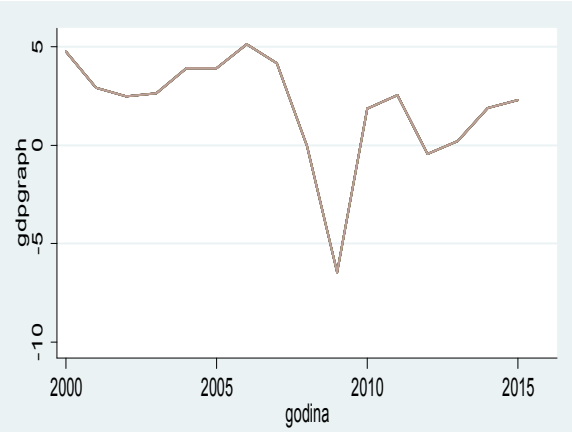
[7] „Koeficijent varijacije omjer je između standardne devijacije i aritmetičke sredine. Taj omjer se može pomnožiti sa 100, i onda predstavlja postotak standardne devijacije u odnosu na aritmetičku sredinu“ (Rozga, 2006., str. 58).

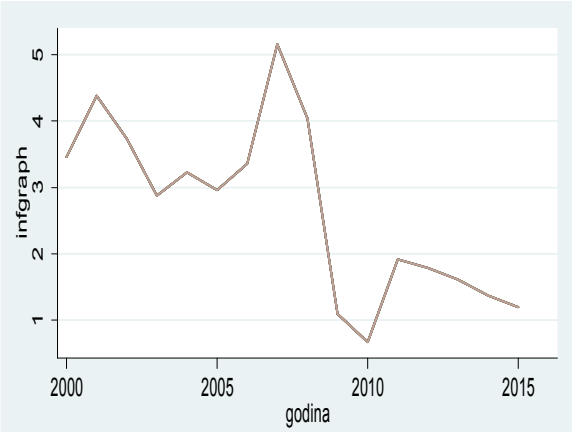


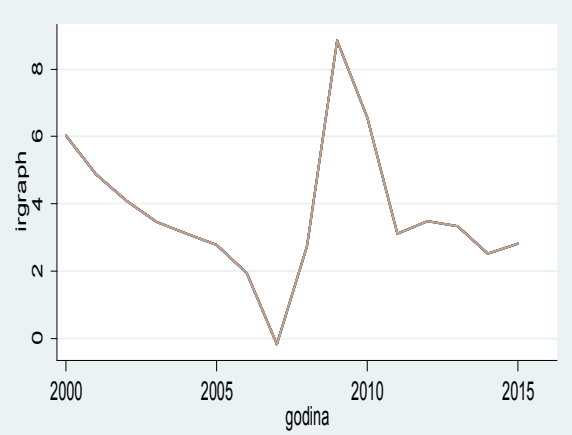
Graf 10: Kretanje prosječne vrijednosti zavisne varijable, bruto domaće štednje

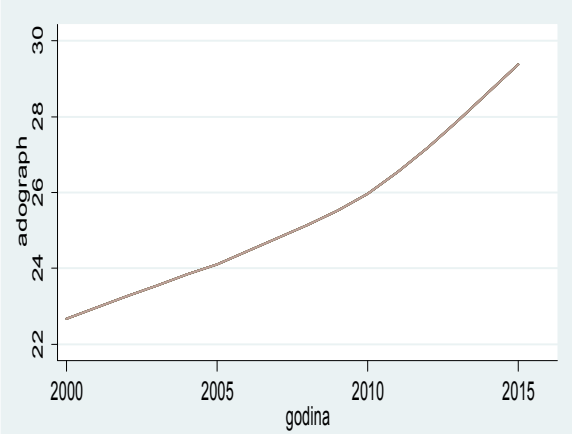
Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

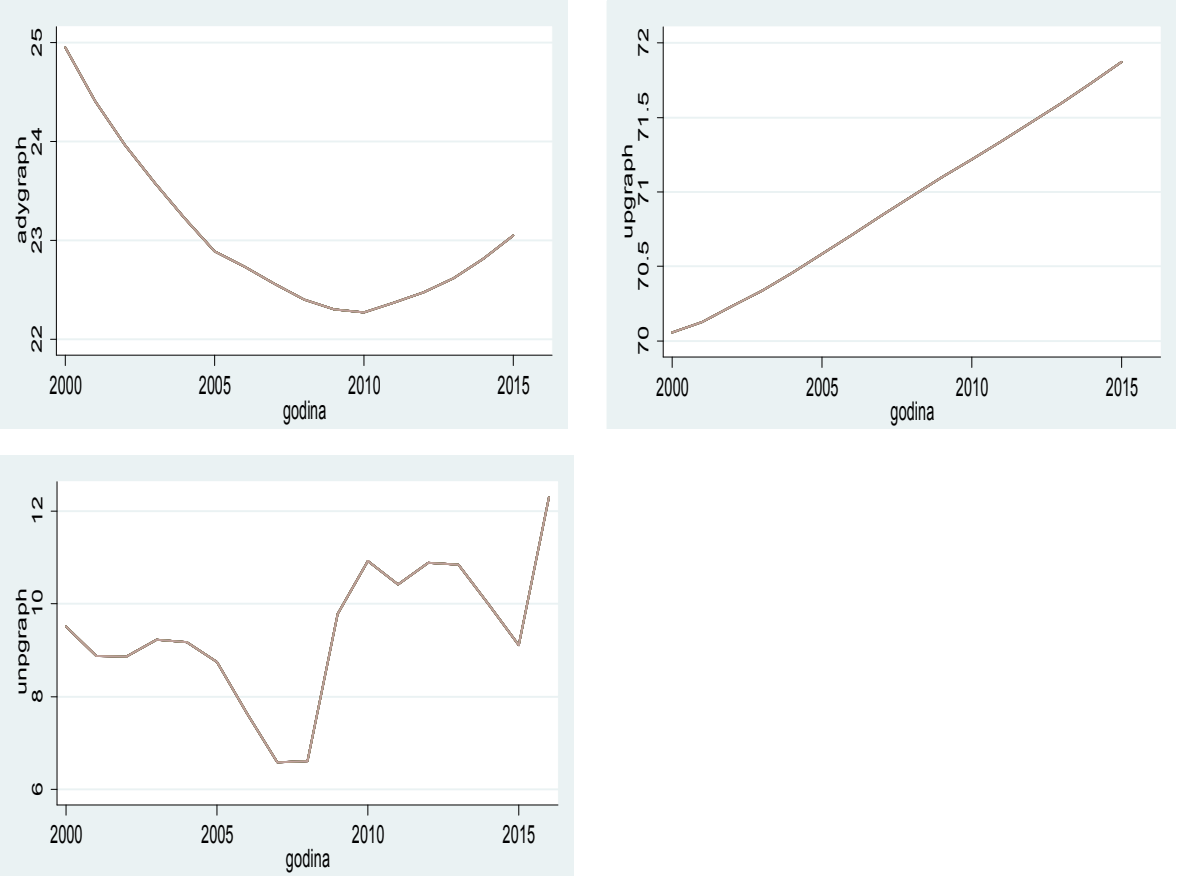
Pregled grafikona objašnjava trend štednje i nezavisnih varijabli tijekom promatranog perioda. U skladu sa teorijskim tvrdnjama ističe se razdoblje *globalne krize*, kao period nestabilnosti, stoga će se provesti i *ispitivanje utjecaja* ***krize*** na štednju tijekom razdoblja 2008.-2010. godine. Isto tako, potvrđuje se pretpostavka kretanja izabranih determinanti. Prosječna štednja zemalja, članica EU, *povećava se prije krize*, a u 2009. godini *događa se snažan pad štednje* stanovništva. Trend nezavisnih varijabli u skladu je sa teorijskim pretpostavkama.











Graf 11: Kretanje prosječnih vrijednosti nezavisnih varijabli po godinama

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Tablica 4: Korelacijska matrica između nezavisnih varijabli

```
. pwcorr gdp inf ir ado ady up unp
```

	gdp	inf	ir	ado	ady	up	unp
gdp	1.0000						
inf	0.4732	1.0000					
ir	-0.4954	-0.6611	1.0000				
ado	-0.2941	-0.2302	-0.1835	1.0000			
ady	0.0406	-0.0360	0.1201	-0.0717	1.0000		
up	-0.1117	-0.1928	-0.0991	0.2389	0.5847	1.0000	
unp	-0.0654	-0.2319	0.3532	-0.0026	-0.1089	-0.0640	1.0000

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Rezultati korelacijske analize ne ukazuju na problem multikolineranosti. Koeficijenti korelacije ne pokazuju snažnu pozitivnu/negativnu povezanost nezavisnih varijabli, stoga se navodi da *ne postoji problem mulitkolinearnosti*. Uočava se *srednje jaka negativna povezanost* kamatne stope i inflacije, -0,6611, što bi moglo uzrokovati problem mulitkolinearnosti uvrštavanjem navedenih varijabli istodobno. Isto tako, rezultati prikazuju *srednje jaku pozitivnu povezanost* udjela urbanog stanovništva i mlađe ovisne skupine sa koeficijentom 0,5847.

Nadalje, u nastavku empirijske procjene koristi se ***korigirani procjenitelj fiksnog efekta*** koji je *najprikladniji za procjenu prema dijagnostičkim testovima*.

5.2. Rezultati istraživanja

Prema dobivenim rezultatima testiranja ispitati će se *istinitost postavljenih hipoteza*.

Tablica 5: Rezultati svih modela

	(AB) gds	(BB) gds	(LSDV) gds	(LSDVC-ab) gds	(LSDVC-bb) gds
L.gds	0.572** (0.229)	0.655** (0.294)	0.771*** (0.0807)	0.886*** (0.0870)	0.966*** (0.0845)
gdp	0.351*** (0.0849)	0.346*** (0.0526)	0.266*** (0.0386)	0.277*** (0.0374)	0.295*** (0.0417)
inf	0.804 (0.492)	0.734* (0.375)	0.186** (0.0712)	0.172** (0.0744)	0.171** (0.0815)
ir	0.595* (0.316)	0.673** (0.284)	0.171*** (0.0646)	0.159** (0.0649)	0.155** (0.0717)
ado	0.606 (0.465)	0.655* (0.349)	0.255*** (0.0751)	0.218** (0.0883)	0.222** (0.0943)
ady	-1.160*** (0.296)	-1.050* (0.544)	-0.513*** (0.132)	-0.439*** (0.157)	-0.360** (0.163)
up	1.061 (7.133)	0.161* (0.0902)	0.162 (0.139)	0.144 (0.163)	0.119 (0.181)
unp	0.108 (0.311)	-0.0627 (0.170)	0.101 (0.0700)	0.129** (0.0654)	0.168** (0.0742)
_cons	-57.62 (489.9)	0 (0)	-2.882 (10.44)		
N	91	103	103	103	103
R^2			0.715		

Standard errors in parentheses
* $p < 0.1$, ** $p < 0.05$, *** $p < 0.01$
Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Postoje razlike između prikazanih pet različitih procjenitelja koji su vidljivi u tablici 5. Što se tiče statističke značajnosti vidljive su razlike kod većine nezavisnih varijabli kao i varijacije u rezultatima standardnih grešaka. Dinamički panel modeli sadržavaju zavisnu varijablu s jednim vremenskim pomakom unatrag, a statistička značajnost koeficijenta uz zavisnu varijablu s pomakom koja se uočava u tablici ***opravdava*** *korištenje dinamičkog modela.* Vrijednosti svih varijabli se u potpunosti razlikuju kroz modele dok je smjer utjecaja određenih nezavisnih varijabli drugačiji od očekivanih vrijednosti za pojedine modele. Vrijednost zavisne varijable je sukladna pretpostavkama i nalazi se u intervalu između 0 i 1. Iz tablice je vidljivo da najviše statistički značajnih nezavisnih varijabli ima model procjenjen s *korigiranim procjeniteljem fiksnog efekta*. Navedeni procjenitelj opravdano je koristiti s obzirom da se istraživanje provodi

nad ***13 jedinica promatranja za 17 opažanja*** što ga čini najboljim procjeniteljem za testiranje. Naime, uvjet korištenja ovog procjenitelja je da *broj jedinica promatranja mora biti manji od broja opažanja.* Procjenjen model dostupan je u prilogu (tablica 14).

Korigirani procjenitelj fiksnog efekta *ima bolja svojstva u odnosu na AB i BB procjenitelj kada je broj jedinica promatranja malen*, (Škrabić Perić, 2015). Također, ovaj procjenitelj je nekonzistentan za konačne vrijednosti T i N $\rightarrow\infty$, stoga konzistentnost ovisi o broju opažanja. Nedostatak ovog procjenitelja što pretpostavlja da su sve *nezavisne varijable* ***egzogene***, dok je u usporedbi sa modelima AB i BB *nepristran* s obzirom da *ne podcjenjuje* vrijednost parametra uz zavisnu varijablu s pomakom. *AB procjenitelj* ima prednost samo kada je broj jedinica promatranja *veći* u odnosu na promatrano razdoblje, kao i *BB procjenitelj*, što u ovom radu nije slučaj, (Škrabić Perić, 2015). Pretpostavka procjenitelja da su sve *nezavisne varijable* ***egzogene*** ističe mogućnost *problema* ***endogenosti***. Naime, potencijalna povezanost *štednje i dohotka* doprinosi otvaranju pitanja *problema endogenosti,* tj. što je *uzrok*, a što *posljedica* pojave.

Tablica 6: Sargan test, Arellano-Bondov (AB) procjenitelj u dva koraka

```
. estat sargan
Sargan test of overidentifying restrictions
        H0: overidentifying restrictions are valid

        chi2(13)     =  3.641566
        Prob > chi2  =    0.9944
```

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Valjanost instrumenata koje se koriste u analizi testiraju se Sarganovim testom, (Škrabić Perić, 2015). Provedeni Sargan test za AB procjenitelj u dva koraka (tablica 6) prikazuje vrijednost ***0.9944*** > 0.05 na temelju čega se *prihvaća nulta hipoteza* koja objašnjava da su odabrane instrumentalne varijable nekorelirane s rezidualima, tj. da ***ne postoji*** *problem endogenosti.*

Tablica 7: Test autokorelacije reziduala

```
. estat ab

Arellano-Bond test for zero autocorrelation in first-differenced errors
```

Order	z	Prob > z
1	-.33094	0.7407
2	-.51347	0.6076

```
H0: no autocorrelation
```

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Nadalje, pored Sargan testa, test autokorelacije reziduala se provodi u istraživanjima kako bi se utvrdila konzistentnost procjene parametara. Postojanje autokorelacije drugog reda objašnjava probleme pri specifikaciji modela, tj. da neki uvjeti nisu zadovoljeni, (Škrabić Perić, 2015).

Test autokorelacije reziduala drugog reda iznosi ***0.6076*** > 0.05 što *potvrđuje nultu hipotezu*, tj. da ***ne postoji*** *problem autokorelacije* drugog reda među prvim diferencijama reziduala.

Fiksni procjenitelj LSDVC-bb u odnosu na AB i BB model koji uočenu pristarnost definiraju kao korelaciju između zavisne varijable iz prethodnog razdoblja i slučajne pogreške rješavaju uvođenjem instrumentalnih varijabli, „Kiviet (1995) je problem pristranosti riješio tako da je izveo formulu koja aproksimira uočenu pristranost" (Škrabić Perić, 2015). Isto tako, „Roodman (2009) ističe opasnost korištenja upotrebe velikog broja instrumentalnih varijabli koje mogu dati pristraniju procjenu" (Škrabić Perić, 2015). Pored toga, korigirani procjenitelj fiksnog efekta postaje popularan doprinosom Bruno (2005) koji je omogućio primjenu modela na nebalansirane podatke. Navedeni autor je dokazao bolja svojstva procjenitelja u odnosu na AB i BB kada je broj jedinica promatranja malen. Spomenuti problem pristranosti Kiviet (1995) uklanja kroz sljedeće formule; korelaciju između α_i i $gds_{i,t-1}$, tj. zavisne varijable iz prethodnog razdoblja, rješava uvođenjem prosječnih vrijednosti za zavisne varijable, nezavisne varijable i greške relacije za jedinicu promatranja i, za t razdoblja; nakon toga se od modela uobičajnog zapisa oduzme model sa uvrštenim prosječnim vrijednostima; *dobiveni model ne uključuje fiksni efekt*, ali ostaje problem korelacije između zavisne varijable iz prethodnog razdoblja i prosječne greške relacije.

U konačnici, „*da bi se mogla izračunati pristranost procjene,* potrebne su stvarne vrijednosti parametara δ i varijanca slučajne pogreške parametara σ_ε^2. S obzirom da su stvarne vrijednosti nepoznate, one se aproksimiraju procjenama jednog od konzistentnih procjenitelja, tj. procjenama Andersonovim i Hsiaovim procjeniteljem, Arellanovim i Bondovim procjeniteljem ili Blundellovim i Bondovim procjeniteljem" (Škrabić Perić, 2015).

Na kraju, prema dobivenim rezultatima, može se zaključiti da ispitivanje **istraživačke hipoteze $H_{1.1}$** *potvrđuje pozitivan doprinos* ***dohotka*** na razinu štednje, tj. uočava se *značajan* doprinos razine *dohotka* stanovništva na motiv pojedinca za štednju. Prema tome, *pozitivan* utjecaj dohotka u skladu je sa teorijskim tvrdnjama i empirijskim istraživanjima. Nadalje, ispituje se **istraživačka hipoteza $H_{1.2}$**, koja pretpostavlja utjecaj inflacije na štednju, često dvosmislen, može biti *pozitivan i negativan*. Istraživanje pokazuje *pozitivan utjecaj* ***inflacije*** za sve korištene procjenitelje. Navedeni doprinos se objašnjava kroz pojam makroekonomske nesigurnosti gdje pojedinac motivima *predostrožnosti* uslijed visoke stope inflacije povećava razinu štednje. U konačnici, statistička značajnost inflacije potvrđuje se pri razini signifikantnosti od 95%. Isto tako, rezultat značajnosti uočava se kod ispitivanja utjecaja nezaposlenosti na razinu štednje koja se odnosi na **istraživačku hipotezu $H_{1.3}$**. Pored inflacije,

kao mjera makroekonomske nesigurnosti koja *pozitivno* utječe na štednju je i varijabla ***nezaposlenot***. Ovakav smjer utjecaja se objašnjava motivom *predostrožnosti* i u skladu je sa empirijskim dokazima istraživanja Rocher i Stierle (2015), dok teorija naglašava mogućnost i pozitivnog i negativnog utjecaja. Ispitivanjem **istraživačke hipoteze $H_{1.4}$** potvrđuje se pretpostavka o *pozitivnom utjecaju* ***kamatne stope*** na razinu štednje u promatranom periodu. U ovom kontekstu, pojedinac kamatnu stopu promatra kao nagradu za odricanje od likvidnosti, a *povećanje* kamatne stope doprinosi spremnosti deponiranja novca.

Pored navedenih ***ekonomskih***, istraživanje obuhvaća i analizu ***demografskih determinanti***. Za ***ispitivanje*** **istraživačke hipoteze $H_{2.1}$** koriste se dvije mjere; *pokazatelj udjela starije ovisne skupine u radno aktivnoj kategoriji i pokazatelj udjela mlađe ovisne skupine u radno aktivnoj kategoriji*. Teorijska objašnjenja navode mogućnost dvosmislenog utjecaja; može biti *pozitivan i negativan* što ovo istraživanje i potvrđuje. Rezultati istraživanja pokazuju *značajan i* ***pozitivan*** *utjecaj* ***starije ovisne skupine*** na razinu štednje, dok udio ***mlađe ovisne skupine*** ističe *značajan i* ***negativan*** utjecaj na razinu štednje. Varijable su *statistički značajne* pri razini signifikantnosti od 95%. Na kraju, prema dobivenim podacima iz modela ne prihvaća se **istraživačka hipoteza $H_{2.2}$** koja ispituje *negativan utjecaj* ***stupnja urbanizacije*** na razinu štednje. Navedena varijabla ***nije statistički značajna*** uz napomenu kako je smjer utjecaja pozitivan.

Empirijsko istraživanje promatra i utjecaj *globalne financijske krize* na štednju konstruiranjem ***dummy*** *(binarne) varijable* u regresijskom modelu. Uvođenjem dummy varijable, period krize 2008.-2010. godine *sadrži vrijednosti* 1, dok period koji *ne uključuje* razdoblje utjecaja svjetske krize poprima vrijednost 0. Proširivanjem modela analize, provodi se ispitivanje **istraživačke hipoteze $H_{3.1}$** o utjecaju ***krize*** na štednju. Testiranjem se uočava ***negativan*** i ***značajan*** utjecaj pri razini signifikantnosti od 90%, stoga se istraživačka hipoteza *može prihvatiti.*

Prema dobivenim podacima (tablica 8) koja uključuje analizu utjecaja krize uvođenjem ***dummy*** *(binarnih) varijabli* uočavaju se razlike između korištenih procjenitelja te dobivenih rezultata (tablica 5) koji *nisu promatrali* utjecaj globalne krize. Koeficijenti uz zavisnu varijablu s pomakom su statistički značajni i nalaze se u intervalu između 0 i 1. Uvedena binarna varijabla ***kriza*** statistički je značajna korištenjem ***korigiranog procjenitelja fiksnog efekta*** pri razini signifikantnosti od 90%, dok kod ostalih procjenitelja ***nije statistički značajna***. Vrijednosti koeficijenta promatranih varijabli *razlikuju se* u odnosu na testiranje modela bez promatranja globalne krize, dok je smjer utjecaja ostao identičan podacima iz tablice 5. Tijekom razdoblja krize *smanjen* je utjecaj varijabli *dohotka i o hranitelju obitelji ovisne skupine*, starije

populacije, na štednju, dok se za preostale varijable uočava *snažniji utjecaj* na štednju nego kod modela bez uvođenja dummy varijable.

Tablica 8: Rezultati svih modela; uključena varijabla kriza

	(AB) gds	(BB) gds	(LSDV) gds	(LSDVC-ab) gds	(LSDVC-bb) gds
L.gds	0.521** (0.236)	0.905*** (0.128)	0.772*** (0.0799)	0.882*** (0.0832)	0.952*** (0.0780)
gdp	0.446*** (0.118)	0.611*** (0.195)	0.228*** (0.0449)	0.243*** (0.0439)	0.251*** (0.0486)
inf	0.977*** (0.374)	0.979*** (0.328)	0.187*** (0.0704)	0.175** (0.0732)	0.184** (0.0813)
ir	1.195** (0.500)	0.537 (0.329)	0.169*** (0.0640)	0.157** (0.0640)	0.157** (0.0707)
ado	1.027 (0.989)	2.373** (1.202)	0.233*** (0.0755)	0.204** (0.0864)	0.214** (0.0899)
ady	-1.077*** (0.285)	-0.537 (0.448)	-0.581*** (0.137)	-0.495*** (0.162)	-0.441*** (0.168)
up	4.061 (8.331)	-0.890 (0.594)	0.155 (0.137)	0.143 (0.160)	0.112 (0.174)
unp	-0.135 (0.198)	1.124** (0.528)	0.0979 (0.0693)	0.128* (0.0656)	0.171** (0.0738)
kriza	4.595 (11.92)	0.943 (1.169)	-0.664 (0.400)	-0.566 (0.377)	-0.701* (0.422)
_cons	-276.6 (559.7)	0 (0)	-0.0620 (10.47)		
N	91	103	103	103	103
R^2			0.724		

Standard errors in parentheses
* $p < 0.1$, ** $p < 0.05$, *** $p < 0.01$
Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

5. ZAKLJUČAK

Brojni su motivi stanovništva za štednju, a štednja *značajno doprinosi gospodarstvu*. Primjerice, pojedinac ulaganjem štednje putem bankarskih depozita i vrijednosnih papira omogućava kreditiranje što omogućava investiranje i *potiče rast gospodarstva*. S druge strane, prekomjerni dug obuhvaća rast loših kredita što implicira *negativne* posljedice. Uloga pojedinca u gospodarstvu promatra se u obliku deponenta, korisnika osiguranja, ulagača na tržištu kapitala te kao potencijalnog dužnika.

Odluka o štednji je pod utjecajem ekonomskih i demografskih determinanti koje su *predmet* ovog istraživanja, a *cilj* istraživanja je bio ispitati utjecaj ekonomskih i demografskih determinanti na razinu štednje. Također, kao cilj istraživanja navodi se ispitivanje utjecaja *financijske krize* na štednju stanovništva. Opravdanost razmatranja navedenih čimbenika temeljena je na pregledu empirijskih doprinosa istraživanja te istaknutim teorijskim stavovima. U svrhu istraživanja koristila se *panel analiza* s obzirom na analizu vremenske i prostorne komponente istodobno; i to provođenjem ***korigiranog procijenitelja fiksnog efekta,*** na uzorku 13 zemalja članica EU u razdoblju od 2000. do 2016. godine.

Smjer utjecaja odabranih varijabli u skladu je sa teorijskim tvrdnjama. Rezultati empirijskog istraživanja potvrđuju ***pozitivan*** *utjecaj dohotka*. Testiranjem modela uočava se ***pozitivan*** utjecaj *inflacije, kamatne stope i nezaposlenosti* na štednju. Ispitivanje demografskih varijabli provelo se razmatranjem doprinosa varijable *o hranitelju obitelji ovisne skupine i stupnja urbanizacije*. Kao mjera varijable o hranitelju obitelji ovisne skupine koriste se *starije ovisne skupine* koja pokazuje ***pozitivan*** utjecaj, dok *udio mlađe ovisne skupine* ***negativno*** utječe na razinu štednje. Na kraju, *stupanj urbanizacije* ***nije se pokazao*** statistički značajnom determinantom štednje.

Pored navedenog, provedeno je ispitivanje *utjecaja financijske krize* na razinu štednje, te se potvrdila pretpostavka modela o ***negativnom*** utjecaju na štednju. Razmatranje utjecaja krize objašnjava se ulogom u poticanju kućanstva na porast štednje uslijed scenarija *nesigurnosti i straha za budući dohodak*. Prema tome, pojedinac u situaciji krize *povećava štednju* zbog nestabilnosti budućih događaja, potencijalnog rasta stope nezaposlenosti i inflacije. U početnom periodu krize uočava se rast štednje stanovništva, dok empirijsko istraživanje pokazuje ***negativan*** utjecaj na štednju za cjelokupno razdoblje krize između 2008.-2010. godine. Testiranjem modela uz varijablu kriza, smjer utjecaja promatranih varijabli ostao je identičan, dok se vrijednost koeficijenata razlikuje u odnosu na model bez varijable kriza.

Uz navedenu empirijsku potvrdu, istraživanje je obuhvatilo analizu kretanja štednje između promatranih članica. Trend štednje pokazao je brojne razlike između članica EU u razini štednje stanovništva što objašnjava potencijal dostupnih sredstava za investicije putem domaćih izvora financiranja članica. Isto tako, negativne stope štednje pojedinih članica ističu pitanje održivosti duga kućanstva. U konačnici, analizom kretanja štednje ustanovljen je relativno stabilan trend, osim za razdoblje financijske krize što potvrđuje i empirijsko istraživanje.

Nadalje, uočava se tradicionalan pristup pri izboru ulaganja financijske imovine, uz iznimku Danske, Estonije, Finske i Švedske koje preferiraju instrumente tržišta kapitala za plasman novčanih sredstava. Tradicionalan pristup ulaganja putem bankarskih depozita smatra se *najsigurnijim* oblikom ulaganja kojem raste sklonost stanovništva za vrijeme krize. Isto tako, pored depozita uočava se rast ugovaranja životnog osiguranja u periodu nesigurnosti, tj. krize.

LITERATURA

1. Ando, A., Modigliani, F. (1963): The life Cycle Hipothesis of Saving: Aggregate Implications an Tests, The American Economic Review, Vol. 53, No. 1, Part 1 (Mar., 1963), pp. 55-84, [20.2.2017.].
2. Alimi, R., S. (2013): Keynes' Absolute Income Hypothesis and Kuznets Paradox, Department of Economics, Adekunle Ajasin University, Akunbga Akoko, Nigeria.
3. Andrijašević, S., Petranović, V. (1999): Ekonomika osiguranja, Zagreb, Alfa.
4. Babić, M. (2007): Makroekonomija, petnaesto izdanje, MATE d.o.o, Zagreb.
5. Balassa, B. (1992): The Effects of Interest Rates on Saving in Developing Countries, Banca Nazionale del Lavoro Quarterly Review, No. 172.
6. Barghini, T., Pasquali, V. (2015): Household Saving Rates, Global Finance, raspoloživo na: https://www.gfmag.com/global-data/economic-data/916lqg-household-saving-rates [23.2.2017.].
7. Baykara, S., Telatar, E. (n.d.): The Stationarity of Consumption-Income Ratios with Nonlinear And Asymmetric Unit Root Tests: Evidence from Fourteen Transition Economies
8. Bejaković, P. (2003): Nezaposlenost, Financijska teorija i praksa, 27 (4), 659-661, Institut za javne financije, Zagreb, raspoloživo na: http://www.ijf.hr/pojmovnik/PDF/4-03.pdf , [5.3.2017.].
9. Blanchard, O. (2009): Makroekonomija, peto izdanje, Zagreb, 2011., MATE.
10. Browning, M., Lusardi, A. (1996): Household saving: micro theories and micro facts. Journal of Economic literature, Vol. 34, No. 4, pp. 1797–1855.
11. Bruno, G., S., F., (2005): Estimation and Inference in Dynamic Unbalanced Panel-Data Models with A Small Number of Individuals.
12. Brueggeman, W., B., Fisher, J., D. (2008): Real Estate Finance and Investments, McGrawHill Education, Thirteenth Edition, New York.
13. Buti at el. (2009): Economic Crisis in Europe: Causes, Consequences and Responses, EUROPEAN ECONOMY 7|2009, European Commission.

14. Callen, T., Thimann, C. (1997): Empirical Determinants of Household Saving: Evidence from OECD Countries, International Monetary Fund, WP/97/181, raspoloživo na: https://www.imf.org/external/pubs/ft/wp/wp97181.pdf, [7.3.2017.].

15. Callen, T., Thimann, C. (1997): Empirical Determinants of Household Saving: Evidence from OECD Countries, IMF Working paper, WP/97/181.

16. Ćurak, M., Mulač, D. (2011): Odrednice depozitnog potencijala banaka u Republici Hrvatskoj. U: Vidučić, Lj., ur., Mala i srednja poduzeća: Financijska politika i ekonomsko financijski okvir podrške. Split: Ekonomski fakultet, str. 71-85.

17. Ćurak, M., Jakovčević, D. (2007): Osiguranje i rizici, RRiF-plus, Zagreb.

18. DBS Group Research, India: savings rate in need of a boost, 2016, Economics.

19. Duesenberry, J., S. (1967): Income, Savings, and the Theory of Consumer Behavior.

20. EBRD (2011): Transition Report. Crisis and Transition: The People's Perspective." European Bank for Reconstruction and Development.

21. Eicher, S., T., Röhn, O. (2007): Institutional determinantes of economic performance in OECD countries – an institutions climate index, raspoloživo na: http://faculty.washington.edu/te/papers/ERdice.pdf, [21.2.2017.].

22. Esposito at el. (2014): The European Crisis, Harvard University, Analysis and a Novel Intervention, European Parliament.

23. European Commission, HICP-CPI Differences, Directorate D: Economic and Regional Statistics Unit D-4: Price statistics, Eurostat.

24. Foley, J., B. (1993): Tržišta kapitala, Mate, Zagreb.

25. Friedman, M. (1957): A Theory of the Consumption Function, Princeton University Press, Princeton.

26. Gambacorta, L. (2004): How Do Banks Set Interest Rates?, Working Paper 10295, NBER WORKING PAPER SERIES, raspoloživo na: http://www.nber.org/papers/w10295.pdf, [3.5.2017.].

27. Glickman, E., A. (2014): An Introduction to Real Estate Finance, Elsevier, First Edition, Waltham.

28. Globan, T., (2016): Determinante (prekida) priljeva kapitala u Republiku Hrvatsku, Zagreb, raspoloživo na: http://www.hub.hr/hr, [23.3.2017.].

29. Gregurek, M., Vidaković, N. (2013): Bankarsko poslovanje, drugo nepromijenjeno izdanje, Zagreb: Visoko učilište EFFECTUS.

30. Grigoli, F., Herman, A., Schmidt-Hebbel, K. (2014): World Saving, IMF Working Paper Western Hemisphere Department, 2014 International Monetary Fund, raspoloživo na: https://www.imf.org/external/pubs/ft/wp/2014/wp14204.pdf, [15.3.2017.].

31. Hartstein, I. (2013): Australian Household Savings, RBA/ESA Economics Competition 2013, University of New South Wales, ESA.

32. Hebbel, Schmidt, K., Servén, L. (1997): Saving across the World, Puzzles and Policies.

33. Hüfner, F., Koske, I. (2010): Explaining household saving rates in G7 countries: Implications for Germany economics department working papers No.754, raspoloživo na:http://www.oecd.org/officialdocuments/publicdisplaydocumentpdf/?doclanguage=en&cote=eco/wkp(2010)10, [16.3.2017.].

34. Jovančević, R., Globan, T. (2011): Determinante i (Ne)Rezistentnost izravnih stranih ulaganja u uvjetima globalne financijske krize: Primjer Hrvatske, Ekonomski fakultet, Sveučilište u Zagrebu, raspoloživo na: http://web.efzg.hr/RePEc/Chapters/chapter11-01.pdf, [16.3.2017.].

35. Jurman, A. (2008): Financijski potencijal hrvatskih banaka, obilježja i projekcija rasta, Ekonomska istraživanja, br.1, 2009., Ekonomski fakultet Rijeka.

36. Kamakura, A., W., Du, Y., R. (2012): How Economic Contractions and Expansions Affect Expenditure Patterns, Journal of Consumer Research, Vol. 39, No. 2 (August 2012), pp. 229-247, The University of Chicago Press.

37. Karabarbounis, L., Neiman, B. (2012): Declining Labor Shares and the Global Rise of Corporate Saving, University of Chicago and NBER.

38. Katunarić, A. (1988): Banka: principi i praksa bankovnog poslovanja, Zagreb: Centar za informacije i publicitet.

39. Keynes, J.M. (1936.): Opća teorija zaposlenosti, kamate i novca, Izdanje centra za kulturnu djelatnost, Zagreb, 1987.

40. Kiviet, J., F. (1995): On bias, inconsistency, and efficiency of various estimators in dynamic panel data models. Journal of Econometrics 68, 53–78.

41. Kolasa, A., Liberda, B. (2014): Determinants of saving in Poland: Are they different than in other OECD countries?, Working Papers No. 13/2014 (130), University of Warsaw, Faculty of Economic Sciences, raspoloživo na:

http://www.wne.uw.edu.pl/inf/wyd/WP/WNE_WP130.pdf, [19.3.2017.].

42. Koskela, E., Viren, M. (1982): Saving and Inflation: Some International Evidence, Economic Letters, Vol. 9, No. 4.

43. Kukk, M., Staehr, K., (2015): Macroeconomic Factors in Corporate and Household Saving. Evidence from Central and Eastern Europe, Eesti Pank. Working Paper Series, 5/2015, raspoloživo na:

http://www.eestipank.ee/sites/eestipank.ee/files/publication/en/WorkingPapers/2015/wp05_2015.pdf, [15.3.2017.].

44. Laitamäki, J., Järvinen, R. (2013): The Impact of the 2008 Financial Crises on Finnish and American Households, LTA 1 / 1 3 • p . 4 1 – 6 5.

45. Lee, D., S. (2011): Effect of Inflation on the Level of Interest Time Deposit, Faculty of Economic, Accounting Departement, Gunadarma University.

46. Leetmaa, P., Rennie, H., Thiry B. (2009): Household saving rate higher in the EU than in the USA despite lower income, Eurostat, European Commission.

47. Loayza, N., Hebbel, Schmidt, K., Servén, L. (2000): What drives private saving around the world, raspoloživo na:

https://www.researchgate.net/publication/23549173_What_Drives_Private_Saving_Around_the_World, [15.3.2017.].

48. Loayza, N., Lopez, H., Hebbel, Schmidt, K., Servén, L. (1998): Saving in the world: Stylized facts.

49. Loayza, N., Lopez, H., Hebbel, Schmidt, K., Servén, L. (1998): The World Saving Data Base, raspoloživo na:

http://siteresources.worldbank.org/INTMACRO/Resources/papero.pdf, [17.4.2017.].

50. Lovrinčević, Ž., Marić, Z., Mikulić, D. (2005): Priljev inozemnog kapitala-utjecaj na nacionalnu štednju, domaće investicije i bilancu plaćanja tranzicijskih zemalja srednje i istočne europe, Izvorni znanstveni rad, Zagreb.

51. Mishkin, S.F. (2010): Ekonomija novca, bankarstva i financijskih tržišta, osmo izdanje, Mate, Zagreb.

52. Muradoglu, G., Taskin, F. (1996.): Differences in household savings behavior: Evidence from industrial and developing countries, The Developing Economics.

53. Niculescu-Aron, I., Mihaescu, C. (2012): Determinants of Household Savings in EU:What Policies for Increasing Savings?, The 8th International Strategic Management Conference, Bucharest Academy of Economic Studies, Bucharest 010371, Romania.

54. Orsag, S. (2011): Vrijednosni papiri, Investicije i instrumenti financiranja, Revicon d.o.o, Sarajevo.

55. Orsag, S. (2006): Izvedenice, Hrvatska udruga financijskih analitičara, 2006, Zagreb.

56. Palenzuela at el. (2016): Savings and investment behaviour in the euro area, Occasional Paper Series, No 167, ECB.

57. Pantzar, M., Kytö, H. (2010): Kauppa ja kulutus lamassa – Kahden suhdannekriisin vertailua. Teoksessa Lammi, M., Peura-Kapanen, L. and Timonen, P. (toim.) Kulutuksen määrät ja tyylit talouden muutoksissa. Kuluttajatutkimuskeskuksen vuosikirja 2010, 9-21.

58. Pfnur, A. (2005): Moderni menadžment nekretnina, prijevod s njemačkog, Koraci, Zaprešić.

59. Pojatina, D. (1981): Štednja stanovništva, Institut društvenih nauka, Beograd.

60. Pojatina, D. (2000): Tržište kapitala, Ekonomski fakultet Split, Split.

61. Prati, A., Bartolini, L., Bertola, G. (2002): The Overnight Interbank Market: Evidence from the G-7 and the Euro Zone, raspoloživo na:

https://www.newyorkfed.org/medialibrary/media/research/staff_reports/sr135.pdf, [19.3.2017.].

62. Price, F., Finlay, R. (2014): The Rise in Household Saving, Reserve Bank of Australia.

63. Rocher, S., Stierle, H.M. (2015): Household saving rates in the EU: Why do they differ so much? ISSN 2443-8022 (online), DISCUSSION PAPER 005, raspoloživo na: https://ec.europa.eu/info/sites/info/files/file_import/dp005_en_2.pdf, [16.3.2017.].

64. Röhn, O., Eicher, S., T. (2007): Institutional Determinantes of Economic Performance in OECD Countries – an Institutions Climate Index, CESifo DICE Report 1/2007.

65. Rose, P.S. (2003): Menadžment komercijalnih banaka, četvrto izdanje, Mate, Zagreb.

66. Rose, P.S., Hudgins, S.C. (2015): Upravljanje bankama i financijske usluge, Mate, Zagreb.

67. Rozga, A. (2006): Statistika za ekonomiste, Sveučilište u Splitu, Ekonomski fakultet, Split.

68. Saunders, A., Cornett, M., M. (2006): Financijska tržišta i institucije, Poslovni dnevnik, Masmedia, Zagreb.

69. Schrooten, M., Stephan, S. (2004): Does Macroeconomic Policy Affect Private Savings in Europe? Evidence From a Dynamic Panel Data Model, DIW Discussion Papers, No. 431. German Institute for Economic Research (DIW Berlin).

70. Serres, de A., Pelgrin, F. (2003): The Decline in Private Saving rates in the 1990s in OECD countries: How much can be explained by non-wealth determinants?, raspoloživo na: https://www.oecd.org/eco/monetary/33638821.pdf, [20.3.2017.].

71. Sisek, B. (2005): Strane izravne investicije u Hrvatskoj – uzroci neuspjeha, pregledni znanstveni članak, Zagreb.

72. Škrabić Perić, B. (2015): Nastavni materijali iz kolegija „Analiza vremenskih nizova i panel podataka“. Ekonomski fakultet u Split, Split.

73. Tarkka, J. (1995): Approaches to Deposit Pricing: A Study in Determination of Deposit Interest and Bank Service Charges, Bank of Finland Studies E:2.

74. Tease, W., Dean, A., Elmeskov, J., Hoeller, P. (1991): Real Interest Rate Trends: The Influence of Saving. Investment and other factors, OECD Economic Studies No . 17., raspoloživo na: http://www.oecd.org/tax/public-finance/34258550.pdf, [22.3.2017.].

75. Wei, Y. (2013): The effect of FDI on employment in China, Iowa State University, raspoloživo na:http://lib.dr.iastate.edu/cgi/viewcontent.cgi?article=4386&context=etd, [12.3.2017.].

Web Izvori:

1. Ameco, Annual macro-economic database, raspoloživo na:

   http://ec.europa.eu/economy_finance/ameco/user/serie/SelectSerie.cfm, [17.4.2017.].

2. European Central Bank, Database, raspoloživo na:

   http://sdw.ecb.europa.eu/, [17.4.2017.].

3. Eurostat, Database, raspoloživo na:

   http://ec.europa.eu/eurostat/data/database, [17.4.2017.].

4. Hub, Hrvatska udruga banaka, raspoloživo na: http://www.hub.hr/, [8.3.2017.].

5. Investopedia, raspoloživo na: http://www.investopedia.com/, [10.3.2017.].

6. Moj-bankar, raspoloživo na: http://www.moj-bankar.hr/, [10.3.2017.].

7. OECD, Database, raspoloživo na: https://data.oecd.org/, [17.4.2017.].

8. Wikipedia, raspoloživo na: https://en.wikipedia.org/wiki/Main_Page, [8.3.2017.].

9. World Bank Group, Database, raspoloživo na:

   http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators, [17.4.2017.].

PRILOG 1

Tablica 9: Arellano-Bondov (AB) procjenitelj u dva koraka

```
. xtabond gds gdp inf ir ado ady up unp, lags(1) maxldep(1) twostep artests(2)

Arellano-Bond dynamic panel-data estimation  Number of obs         =        91
Group variable: zemljaid                     Number of groups      =        12
Time variable: godina
                                             Obs per group:    min =         1
                                                               avg =  7.583333
                                                               max =        14

Number of instruments =     22               Wald chi2(8)          =    299.66
                                             Prob > chi2           =    0.0000
Two-step results
```

gds	Coef.	Std. Err.	z	P>|z|	[95% Conf.	Interval]
gds						
L1.	.5724918	.2285996	2.50	0.012	.1244449	1.020539
gdp	.3505121	.0849407	4.13	0.000	.1840313	.5169929
inf	.8037533	.4920534	1.63	0.102	-.1606537	1.76816
ir	.5951238	.3156666	1.89	0.059	-.0235714	1.213819
ado	.6064745	.4649127	1.30	0.192	-.3047377	1.517687
ady	-1.160102	.2958196	-3.92	0.000	-1.739898	-.5803066
up	1.061042	7.132549	0.15	0.882	-12.9185	15.04058
unp	.1084107	.3111024	0.35	0.727	-.5013388	.7181602
_cons	-57.61983	489.9241	-0.12	0.906	-1017.853	902.6138

```
Warning: gmm two-step standard errors are biased; robust standard
         errors are recommended.
Instruments for differenced equation
        GMM-type: L(2/2).gds
        Standard: D.gdp D.inf D.ir D.ado D.ady D.up D.unp
Instruments for level equation
        Standard: _cons
```

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Tablica 10: Sarganov test

```
. estat sargan
Sargan test of overidentifying restrictions
        H0: overidentifying restrictions are valid

        chi2(13)     =  3.641566
        Prob > chi2  =    0.9944
```

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Tablica 11: Blundell – Bondov (BB) procjenitelj u dva koraka

```
. xtdpdsys gds gdp inf ir ado ady up unp, lags(1) maxldep(1) twostep artests(2)

System dynamic panel-data estimation         Number of obs          =       103
Group variable: zemljaid                     Number of groups       =        12
Time variable: godina
                                             Obs per group:    min =         2
                                                               avg =  8.583333
                                                               max =        15

Number of instruments =     36               Wald chi2(8)           =  1.23e+07
                                             Prob > chi2            =    0.0000
Two-step results
```

gds	Coef.	Std. Err.	z	P>|z|	[95% Conf.	Interval]
gds						
L1.	.6549424	.2944167	2.22	0.026	.0778963	1.231989
gdp	.346334	.0525979	6.58	0.000	.2432441	.4494239
inf	.7338019	.3746571	1.96	0.050	-.0005126	1.468116
ir	.6734295	.2839434	2.37	0.018	.1169106	1.229948
ado	.6554175	.3489022	1.88	0.060	-.0284182	1.339253
ady	-1.050153	.5436869	-1.93	0.053	-2.11576	.015454
up	.1605909	.0902298	1.78	0.075	-.0162563	.3374381
unp	-.0626749	.1704112	-0.37	0.713	-.3966747	.271325
_cons	0	(omitted)				

```
Warning: gmm two-step standard errors are biased; robust standard
         errors are recommended.
Instruments for differenced equation
        GMM-type: L(2/2).gds
        Standard: D.gdp D.inf D.ir D.ado D.ady D.up D.unp
Instruments for level equation
        GMM-type: LD.gds
        Standard: _cons
```

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Tablica 12: LSDV procjenitelj

```
. xtreg gds l.gds gdp inf ir ado ady up unp, fe

Fixed-effects (within) regression            Number of obs      =       103
Group variable: zemljaid                     Number of groups   =        12

R-sq:  within  = 0.7151                      Obs per group: min =         2
       between = 0.8589                                     avg =       8.6
       overall = 0.8467                                     max =        15

                                             F(8,83)            =     26.04
corr(u_i, Xb)  = 0.4346                      Prob > F           =    0.0000
```

gds	Coef.	Std. Err.	t	P>|t|	[95% Conf.	Interval]
gds						
L1.	.7711123	.0807162	9.55	0.000	.6105711	.9316536
gdp	.2664727	.038644	6.90	0.000	.1896114	.3433341
inf	.1861476	.0711696	2.62	0.011	.0445942	.327701
ir	.1709625	.0646367	2.64	0.010	.0424026	.2995224
ado	.2550948	.0751128	3.40	0.001	.1056985	.4044912
ady	-.5131525	.1322769	-3.88	0.000	-.7762459	-.2500591
up	.1621063	.1387225	1.17	0.246	-.1138072	.4380198
unp	.1011647	.0699732	1.45	0.152	-.0380091	.2403384
_cons	-2.882266	10.44456	-0.28	0.783	-23.65608	17.89155
sigma_u	1.7734416					
sigma_e	1.0547977					
rho	.73868524	(fraction of variance due to u_i)				

```
F test that all u_i=0:     F(11, 83) =     3.65                 Prob > F = 0.0003
```

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Tablica 13: LSDV i LSDVc(ab) procjenitelj

```
. xtlsdvc gds gdp inf ir ado ady up unp, first lsdv initial (ab) vcov (200)
Note: Bias correction initialized by Arellano and Bond estimator

Arellano-Bond dynamic panel-data estimation     Number of obs      =        91
Group variable: zemljaid                       Number of groups   =        12

                                               Wald chi2(.)       =         .

Time variable: godina                          Obs per group: min =         1
                                                              avg =  7.583333
                                                              max =        14

One-step results
```

D.gds	Coef.	Std. Err.	z	P>|z|	[95% Conf.	Interval]
gds						
LD.	.691906	.0956514	7.23	0.000	.5044328	.8793793
gdp						
D1.	.2817973	.0376027	7.49	0.000	.2080973	.3554973
inf						
D1.	.2605044	.0766002	3.40	0.001	.1103708	.4106381
ir						
D1.	.2497376	.068565	3.64	0.000	.1153527	.3841226
ado						
D1.	.3605368	.0838193	4.30	0.000	.1962539	.5248197
ady						
D1.	-.5087254	.1371782	-3.71	0.000	-.7775898	-.239861
up						
D1.	.1235459	.1568378	0.79	0.431	-.1838506	.4309424
unp						
D1.	.0699929	.0733955	0.95	0.340	-.0738597	.2138455

```
Sargan test of over-identifying restrictions:
         chi2(104) =     67.75      Prob > chi2 = 0.9977

Arellano-Bond test that average autocovariance in residuals of order 1 is 0:
         H0: no autocorrelation    z =  -3.74    Pr > z = 0.0002
Arellano-Bond test that average autocovariance in residuals of order 2 is 0:
         H0: no autocorrelation    z =   0.09    Pr > z = 0.9244
LSDV dynamic regression
```

gds	Coef.	Std. Err.	z	P>|z|	[95% Conf.	Interval]
gds						
L1.	.7711123	.0807162	9.55	0.000	.6129115	.9293132
gdp	.2664727	.038644	6.90	0.000	.1907319	.3422136
inf	.1861476	.0711696	2.62	0.009	.0466578	.3256373
ir	.1709625	.0646367	2.64	0.008	.0442768	.2976482
ado	.2550948	.0751128	3.40	0.001	.1078764	.4023132
ady	-.5131525	.1322769	-3.88	0.000	-.7724104	-.2538946
up	.1621063	.1387225	1.17	0.243	-.1097848	.4339974
unp	.1011647	.0699732	1.45	0.148	-.0359802	.2383095

```
note: Bias correction up to order O(1/T)

LSDVC dynamic regression
(bootstrapped SE)
```

gds	Coef.	Std. Err.	z	P>|z|	[95% Conf.	Interval]
gds						
L1.	.8857961	.0870028	10.18	0.000	.7152738	1.056318
gdp	.277313	.0374333	7.41	0.000	.2039451	.3506809
inf	.172064	.0743951	2.31	0.021	.0262523	.3178757
ir	.1590434	.0649059	2.45	0.014	.0318302	.2862566
ado	.2179189	.0883224	2.47	0.014	.0448102	.3910276
ady	-.4388584	.1573043	-2.79	0.005	-.7471691	-.1305477
up	.143901	.1634956	0.88	0.379	-.1765445	.4643464
unp	.1293949	.0654292	1.98	0.048	.0011562	.2576337

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Tablica 14: LSDV i LSDVc(bb) procjenitelj

```
. xtlsdvc gds gdp inf ir ado ady up unp, first lsdv initial (bb) vcov (200)
Note: Bias correction initialized by Blundell and Bond estimator

Note: Blundell and Bond estimator is implemented through
      the user-written Stata command -xtabond2- by David Roodman,
      Center for Global Development, Washington, DC droodman@cgdev.org
Favoring space over speed. To switch, type or click on mata: mata set matafavor speed, perm.
Warning: Number of instruments may be large relative to number of observations.

Dynamic panel-data estimation, one-step system GMM

Group variable: zemljaid                        Number of obs      =       103
Time variable : godina                          Number of groups   =        12
Number of instruments = 78                      Obs per group: min =         2
Wald chi2(8)  =  49811.77                                      avg =      8.58
Prob > chi2   =     0.000                                      max =        15
------------------------------------------------------------------------------
         gds |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
         gds |
         L1. |   .9866028   .0303359    32.52   0.000     .9271455     1.04606
             |
         gdp |   .2264195   .0352796     6.42   0.000     .1572727    .2955663
         inf |   .0358726   .0508354     0.71   0.480     -.063763    .1355082
          ir |   .0669625   .0514116     1.30   0.193    -.0338024    .1677274
         ado |   .0449792   .0293084     1.53   0.125    -.0124642    .1024226
         ady |  -.1962369   .0683904    -2.87   0.004    -.3302798   -.0621941
          up |   .0372799   .0208089     1.79   0.073    -.0035048    .0780646
         unp |   .0284887     .04021     0.71   0.479    -.0503213    .1072988
------------------------------------------------------------------------------
Instruments for first differences equation
  Standard
    D.(gdp inf ir ado ady up unp)
  GMM-type (missing=0, separate instruments for each period unless collapsed)
    L(1/16).L.gds
Instruments for levels equation
  Standard
    gdp inf ir ado ady up unp
  GMM-type (missing=0, separate instruments for each period unless collapsed)
    D.L.gds
------------------------------------------------------------------------------
Arellano-Bond test for AR(1) in first differences: z =  -3.85  Pr > z =  0.000
Arellano-Bond test for AR(2) in first differences: z =   0.40  Pr > z =  0.692
------------------------------------------------------------------------------
Sargan test of overid. restrictions: chi2(70)    =  83.34  Prob > chi2 =  0.132
  (Not robust, but not weakened by many instruments.)

Difference-in-Sargan tests of exogeneity of instrument subsets:
  GMM instruments for levels
    Sargan test excluding group:     chi2(57)    =  72.94  Prob > chi2 =  0.076
    Difference (null H = exogenous): chi2(13)    =  10.40  Prob > chi2 =  0.661
  iv(gdp inf ir ado ady up unp)
    Sargan test excluding group:     chi2(63)    =  79.07  Prob > chi2 =  0.083
    Difference (null H = exogenous): chi2(7)     =   4.27  Prob > chi2 =  0.749

LSDV dynamic regression
------------------------------------------------------------------------------
         gds |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
         gds |
         L1. |   .7711123   .0807162     9.55   0.000     .6129115    .9293132
             |
         gdp |   .2664727    .038644     6.90   0.000     .1907319    .3422136
         inf |   .1861476   .0711696     2.62   0.009     .0466578    .3256373
          ir |   .1709625   .0646367     2.64   0.008     .0442768    .2976482
         ado |   .2550948   .0751128     3.40   0.001     .1078764    .4023132
         ady |  -.5131525   .1322769    -3.88   0.000    -.7724104   -.2538946
          up |   .1621063   .1387225     1.17   0.243    -.1097848    .4339974
         unp |   .1011647   .0699732     1.45   0.148    -.0359802    .2383095
------------------------------------------------------------------------------


note: Bias correction up to order O(1/T)

LSDVC dynamic regression
(bootstrapped SE)
------------------------------------------------------------------------------
         gds |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
         gds |
         L1. |   .9658998   .0844769    11.43   0.000     .8003281    1.131471
             |
         gdp |   .2945761   .0417216     7.06   0.000     .2128032     .376349
         inf |   .1707395   .0815311     2.09   0.036     .0109414    .3305375
          ir |    .154793   .0716621     2.16   0.031     .0143378    .2952482
         ado |   .2215795      .0943     2.35   0.019     .0367548    .4064042
         ady |  -.3599872    .163306    -2.20   0.027    -.6800611   -.0399133
          up |   .1185281   .1813394     0.65   0.513    -.2368906    .4739468
         unp |   .1675982   .0741763     2.26   0.024     .0222153    .3129811
------------------------------------------------------------------------------
```

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Tablica 15: Korigirani fiksni procjenitelj upotrebom ab procjenitelja

```
. xtlsdvc gds gdp inf ir ado ady up unp, initial (ab) vcov(200)
Note: Bias correction initialized by Arellano and Bond estimator
note: Bias correction up to order O(1/T)

LSDVC dynamic regression
(bootstrapped SE)
```

gds	Coef.	Std. Err.	z	P>|z|	[95% Conf.	Interval]
gds						
L1.	.8857961	.0870028	10.18	0.000	.7152738	1.056318
gdp	.277313	.0374333	7.41	0.000	.2039451	.3506809
inf	.172064	.0743951	2.31	0.021	.0262523	.3178757
ir	.1590434	.0649059	2.45	0.014	.0318302	.2862566
ado	.2179189	.0883224	2.47	0.014	.0448102	.3910276
ady	-.4388584	.1573043	-2.79	0.005	-.7471691	-.1305477
up	.143901	.1634956	0.88	0.379	-.1765445	.4643464
unp	.1293949	.0654292	1.98	0.048	.0011562	.2576337

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Tablica 16: Korigirani fiksni procjenitelj upotrebom ah procjenitelja

```
. xtlsdvc gds gdp inf ir ado ady up unp, initial (ah) vcov(200)
Bias correction initialized by Anderson and Hsiao estimator
note: Bias correction up to order O(1/T)

LSDVC dynamic regression
(bootstrapped SE)
```

gds	Coef.	Std. Err.	z	P>|z|	[95% Conf.	Interval]
gds						
L1.	.8746814	.118288	7.39	0.000	.6428413	1.106522
gdp	.2717172	.0514818	5.28	0.000	.1708147	.3726197
inf	.1586639	.0995942	1.59	0.111	-.0365371	.3538649
ir	.1491428	.0861477	1.73	0.083	-.0197037	.3179892
ado	.2146303	.1377223	1.56	0.119	-.0553004	.484561
ady	-.4476169	.2220284	-2.02	0.044	-.8827846	-.0124492
up	.131555	.2470873	0.53	0.594	-.3527273	.6158373
unp	.1212641	.0963466	1.26	0.208	-.0675718	.3101

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Tablica 17: Korigirani fiksni procjenitelj upotrebom bb procjenitelja

```
. xtlsdvc gds gdp inf ir ado ady up unp, initial (bb) vcov(200)
Note: Bias correction initialized by Blundell and Bond estimator

Note: Blundell and Bond estimator is implemented through
      the user-written Stata command -xtabond2- by David Roodman,
      Center for Global Development, Washington, DC droodman@cgdev.org
note: Bias correction up to order O(1/T)

LSDVC dynamic regression
(bootstrapped SE)
```

gds	Coef.	Std. Err.	z	P>|z|	[95% Conf.	Interval]
gds						
L1.	.9658998	.0844769	11.43	0.000	.8003281	1.131471
gdp	.2945761	.0417216	7.06	0.000	.2128032	.376349
inf	.1707395	.0815311	2.09	0.036	.0109414	.3305375
ir	.154793	.0716621	2.16	0.031	.0143378	.2952482
ado	.2215795	.0943	2.35	0.019	.0367548	.4064042
ady	-.3599872	.163306	-2.20	0.027	-.6800611	-.0399133
up	.1185281	.1813394	0.65	0.513	-.2368906	.4739468
unp	.1675982	.0741763	2.26	0.024	.0222153	.3129811

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Tablica 18: Rezultati modela

	(AB procjenitelj) gds	(AH procjenitelj) gds	(BB procjenitelj) gds
L.gds	0.886***	0.875***	0.966***
	(0.0870)	(0.118)	(0.0845)
gdp	0.277***	0.272***	0.295***
	(0.0374)	(0.0515)	(0.0417)
inf	0.172**	0.159	0.171**
	(0.0744)	(0.0996)	(0.0815)
ir	0.159**	0.149*	0.155**
	(0.0649)	(0.0861)	(0.0717)
ado	0.218**	0.215	0.222**
	(0.0883)	(0.138)	(0.0943)
ady	-0.439***	-0.448**	-0.360**
	(0.157)	(0.222)	(0.163)
up	0.144	0.132	0.119
	(0.163)	(0.247)	(0.181)
unp	0.129**	0.121	0.168**
	(0.0654)	(0.0963)	(0.0742)
N	103	103	103
R^2			

Standard errors in parentheses
* $p < 0.1$, ** $p < 0.05$, *** $p < 0.01$

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Tablica 19: Korigirani fiksni procjenitelj upotrebom ab procjenitelja s lagiranim nezavisnim varijablama

```
. xtlsdvc gds lgdp linf lir lado lady lup lunp, initial (ab) vcov (200)
Note: Bias correction initialized by Arellano and Bond estimator
note: Bias correction up to order O(1/T)

LSDVC dynamic regression
(bootstrapped SE)
```

gds	Coef.	Std. Err.	z	P>|z|	[95% Conf.	Interval]
gds						
L1.	.6674658	.0939077	7.11	0.000	.4834101	.8515214
lgdp	.1389292	.0456067	3.05	0.002	.0495417	.2283167
linf	-.0347779	.0994202	-0.35	0.726	-.229638	.1600821
lir	-.0126932	.089768	-0.14	0.888	-.1886352	.1632488
lado	.0498556	.1051942	0.47	0.636	-.1563212	.2560324
lady	-.4257997	.1695762	-2.51	0.012	-.7581629	-.0934365
lup	.0741396	.1893446	0.39	0.695	-.2969689	.4452481
lunp	.1819971	.0830769	2.19	0.028	.0191693	.3448248

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Tablica 20: Korigirani fiksni procjenitelj upotrebom ah procjenitelja s lagiranim nezavisnim varijablama

```
. xtlsdvc gds lgdp linf lir lado lady lup lunp, initial (ah) vcov (200)
Bias correction initialized by Anderson and Hsiao estimator
note: Bias correction up to order O(1/T)

LSDVC dynamic regression
(bootstrapped SE)
```

gds	Coef.	Std. Err.	z	P>|z|	[95% Conf.	Interval]
gds						
L1.	.6525634	.1166319	5.60	0.000	.423969	.8811577
lgdp	.1386365	.059483	2.33	0.020	.022052	.2552211
linf	-.0319005	.1372229	-0.23	0.816	-.3008524	.2370515
lir	-.0108133	.1229222	-0.09	0.930	-.2517364	.2301099
lado	.0610202	.1482841	0.41	0.681	-.2296113	.3516517
lady	-.4544702	.2375972	-1.91	0.056	-.9201521	.0112117
lup	.1006322	.2708815	0.37	0.710	-.4302859	.6315502
lunp	.1804385	.1116331	1.62	0.106	-.0383583	.3992353

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Tablica 21: Korigirani fiksni procjenitelj upotrebom bb procjenitelja s lagiranim nezavisnim varijablama

```
. xtlsdvc gds lgdp linf lir lado lady lup lunp, initial (bb) vcov (200)
Note: Bias correction initialized by Blundell and Bond estimator

Note: Blundell and Bond estimator is implemented through
      the user-written Stata command -xtabond2- by David Roodman,
      Center for Global Development, Washington, DC droodman@cgdev.org
note: Bias correction up to order O(1/T)

LSDVC dynamic regression
(bootstrapped SE)
```

gds	Coef.	Std. Err.	z	P>|z|	[95% Conf.	Interval]
gds						
L1.	.7563794	.0860595	8.79	0.000	.5877058	.9250529
lgdp	.1415872	.0537027	2.64	0.008	.0363318	.2468427
linf	-.033593	.1138025	-0.30	0.768	-.2566419	.1894559
lir	-.014465	.1029865	-0.14	0.888	-.2163149	.1873849
lado	.0447818	.1198029	0.37	0.709	-.1900275	.2795911
lady	-.3983713	.1942491	-2.05	0.040	-.7790925	-.0176502
lup	.0675279	.232134	0.29	0.771	-.3874464	.5225022
lunp	.1929846	.0948124	2.04	0.042	.0071557	.3788136

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Tablica 22: Rezultati modela

	(AB) gds	(AH) gds	(BB) gds
L.gds	0.667*** (0.0939)	0.653*** (0.117)	0.756*** (0.0861)
lgdp	0.139*** (0.0456)	0.139** (0.0595)	0.142*** (0.0537)
linf	-0.0348 (0.0994)	-0.0319 (0.137)	-0.0336 (0.114)
lir	-0.0127 (0.0898)	-0.0108 (0.123)	-0.0145 (0.103)
lado	0.0499 (0.105)	0.0610 (0.148)	0.0448 (0.120)
lady	-0.426** (0.170)	-0.454* (0.238)	-0.398** (0.194)
lup	0.0741 (0.189)	0.101 (0.271)	0.0675 (0.232)
lunp	0.182** (0.0831)	0.180 (0.112)	0.193** (0.0948)
N	111	111	111
R^2			

Standard errors in parentheses
* $p < 0.1$, ** $p < 0.05$, *** $p < 0.01$
Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Tablica 23: Obični LSDV s lagiranim nezavisnim varijablama

```
. xtreg gds l.gds lgdp linf lir lado lady lup lunp, fe

Fixed-effects (within) regression               Number of obs      =       111
Group variable: zemljaid                        Number of groups   =        12

R-sq:  within  = 0.6213                         Obs per group: min =         3
       between = 0.7993                                        avg =       9.3
       overall = 0.7897                                        max =        15

                                                F(8,91)            =     18.66
corr(u_i, Xb)  = 0.5892                         Prob > F           =    0.0000
```

gds	Coef.	Std. Err.	t	P>|t|	[95% Conf.	Interval]
gds						
L1.	.5551788	.0862974	6.43	0.000	.3837597	.7265979
lgdp	.1434579	.0443043	3.24	0.002	.0554529	.2314628
linf	-.0311975	.0789617	-0.40	0.694	-.1880452	.1256502
lir	-.0125547	.0704314	-0.18	0.859	-.152458	.1273486
lado	.075002	.0983737	0.76	0.448	-.1204052	.2704092
lady	-.4909608	.1497615	-3.28	0.001	-.7884435	-.193478
lup	.124717	.1593312	0.78	0.436	-.1917748	.4412089
lunp	.1711888	.0749524	2.28	0.025	.022305	.3200726
_cons	10.26186	11.94558	0.86	0.393	-13.46657	33.9903
sigma_u	2.334004					
sigma_e	1.2327036					
rho	.7818962	(fraction of variance due to u_i)				

```
F test that all u_i=0:     F(11, 91) =     3.42                 Prob > F = 0.0005
```

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Tablica 24: LSDV s lagiranim nezavisnim varijablama

```
. xtlsdvc gds lgdp linf lir lado lady lup lunp, first lsdv initial (bb) vcov (200)
Note: Bias correction initialized by Blundell and Bond estimator

Note: Blundell and Bond estimator is implemented through
      the user-written Stata command -xtabond2- by David Roodman,
      Center for Global Development, Washington, DC droodman@cgdev.org
Favoring space over speed. To switch, type or click on mata: mata set matafavor speed, perm.
Warning: Number of instruments may be large relative to number of observations.

Dynamic panel-data estimation, one-step system GMM

Group variable: zemljaid                        Number of obs      =       111
Time variable : godina                          Number of groups   =        12
Number of instruments = 81                      Obs per group: min =         3
Wald chi2(8)  =  38775.00                                      avg =      9.25
Prob > chi2   =      0.000                                     max =        15

------------------------------------------------------------------------------
         gds |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
         gds |
         L1. |    .9776782   .0340369    28.72   0.000      .910967    1.044389
             |
        lgdp |    .0693048   .0405833     1.71   0.088     -.010237    .1488465
        linf |   -.0705398   .0584691    -1.21   0.228    -.1851372    .0440576
         lir |   -.0252211   .0561456    -0.45   0.653    -.1352644    .0848221
        lado |    .0057826   .0344217     0.17   0.867    -.0616826    .0732478
        lady |   -.0672481   .0747912    -0.90   0.369    -.2138361    .0793399
         lup |    .0212132   .0244134     0.87   0.385    -.0266362    .0690625
        lunp |    .0823732   .0434787     1.89   0.058    -.0028434    .1675898
------------------------------------------------------------------------------
Instruments for first differences equation
  Standard
    D.(lgdp linf lir lado lady lup lunp)
  GMM-type (missing=0, separate instruments for each period unless collapsed)
    L(1/16).L.gds
Instruments for levels equation
  Standard
    lgdp linf lir lado lady lup lunp
  GMM-type (missing=0, separate instruments for each period unless collapsed)
    D.L.gds
------------------------------------------------------------------------------
Arellano-Bond test for AR(1) in first differences: z =  -2.64  Pr > z =  0.008
Arellano-Bond test for AR(2) in first differences: z =  -0.61  Pr > z =  0.544
------------------------------------------------------------------------------
Sargan test of overid. restrictions: chi2(73)    =  90.10  Prob > chi2 =  0.085
  (Not robust, but not weakened by many instruments.)

Difference-in-Sargan tests of exogeneity of instrument subsets:
  GMM instruments for levels
    Sargan test excluding group:     chi2(61)    =  81.68  Prob > chi2 =  0.040
    Difference (null H = exogenous): chi2(12)    =   8.42  Prob > chi2 =  0.751
  iv(lgdp linf lir lado lady lup lunp)
    Sargan test excluding group:     chi2(66)    =  79.84  Prob > chi2 =  0.118
    Difference (null H = exogenous): chi2(7)     =  10.26  Prob > chi2 =  0.174

LSDV dynamic regression

------------------------------------------------------------------------------
         gds |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
         gds |
         L1. |    .5551788   .0862974     6.43   0.000      .3860391    .7243186
             |
        lgdp |    .1434579   .0443043     3.24   0.001      .0566231    .2302926
        linf |   -.0311975   .0789617    -0.40   0.693     -.1859596    .1235646
         lir |   -.0125547   .0704314    -0.18   0.859     -.1505977    .1254883
        lado |     .075002   .0983737     0.76   0.446     -.1178068    .2678108
        lady |   -.4909608   .1497615    -3.28   0.001     -.7844879   -.1974337
         lup |     .124717   .1593312     0.78   0.434     -.1875664    .4370004
        lunp |    .1711888   .0749524     2.28   0.022      .0242847    .3180929
------------------------------------------------------------------------------

note: Bias correction up to order O(1/T)

LSDVC dynamic regression
(bootstrapped SE)

------------------------------------------------------------------------------
         gds |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
         gds |
         L1. |    .7563794   .0860595     8.79   0.000      .5877058    .9250529
             |
        lgdp |    .1415872   .0537027     2.64   0.008      .0363318    .2468427
        linf |    -.033593   .1138025    -0.30   0.768     -.2566419    .1894559
         lir |   -.014465   .1029865    -0.14   0.888     -.2163149    .1873849
        lado |    .0447818   .1198029     0.37   0.709     -.1900275    .2795911
        lady |   -.3983713   .1942491    -2.05   0.040     -.7790925   -.0176502
         lup |    .0675279    .232134     0.29   0.771     -.3874464    .5225022
        lunp |    .1929846   .0948124     2.04   0.042      .0071557    .3788136
------------------------------------------------------------------------------
```

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Tablica 25: Rezultati modela

	(Dinamički LSDV) gds	(LSDVC-bb) gds
L.gds	0.555***	0.756***
	(0.0863)	(0.0861)
lgdp	0.143***	0.142***
	(0.0443)	(0.0537)
linf	-0.0312	-0.0336
	(0.0790)	(0.114)
lir	-0.0126	-0.0145
	(0.0704)	(0.103)
lado	0.0750	0.0448
	(0.0984)	(0.120)
lady	-0.491***	-0.398**
	(0.150)	(0.194)
lup	0.125	0.0675
	(0.159)	(0.232)
lunp	0.171**	0.193**
	(0.0750)	(0.0948)
_cons	10.26	
	(11.95)	
N	111	111
R^2	0.621	

Standard errors in parentheses
* $p < 0.1$, ** $p < 0.05$, *** $p < 0.01$

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Tablica 26: Rezultati LSDV modela, korigiranog procjenitelja fiksnog efekta (LSDVc) i LSDVCa sa lagiranim varijablama

	(Dinamički) gds	(LSDVC-BB) gds	(LSDVc-bb,lag.) gds
L.gds	0.771***	0.966***	0.756***
	(0.0807)	(0.0845)	(0.0861)
gdp	0.266***	0.295***	
	(0.0386)	(0.0417)	
inf	0.186**	0.171**	
	(0.0712)	(0.0815)	
ir	0.171***	0.155**	
	(0.0646)	(0.0717)	
ado	0.255***	0.222**	
	(0.0751)	(0.0943)	
ady	-0.513***	-0.360**	
	(0.132)	(0.163)	
up	0.162	0.119	
	(0.139)	(0.181)	
unp	0.101	0.168**	
	(0.0700)	(0.0742)	
lgdp			0.142***
			(0.0537)
linf			-0.0336
			(0.114)
lir			-0.0145
			(0.103)
lado			0.0448
			(0.120)
lady			-0.398**
			(0.194)
lup			0.0675
			(0.232)
lunp			0.193**
			(0.0948)
_cons	-2.882		
	(10.44)		
N	103	103	111
R^2	0.715		

Standard errors in parentheses
* $p < 0.1$, ** $p < 0.05$, *** $p < 0.01$

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Tablica 27: Arellano – Bondov procjenitelj u dva koraka

```
. xtabond gds gdp inf ir ado ady up unp, lags(1) maxldep(1) twostep artests(2)

Arellano-Bond dynamic panel-data estimation  Number of obs         =        91
Group variable: zemljaid                     Number of groups      =        12
Time variable: godina
                                             Obs per group:    min =         1
                                                               avg =  7.583333
                                                               max =        14

Number of instruments =     22               Wald chi2(8)          =    299.66
                                             Prob > chi2           =    0.0000
Two-step results
```

gds	Coef.	Std. Err.	z	P>|z|	[95% Conf.	Interval]
gds						
L1.	.5724918	.2285996	2.50	0.012	.1244449	1.020539
gdp	.3505121	.0849407	4.13	0.000	.1840313	.5169929
inf	.8037533	.4920534	1.63	0.102	-.1606537	1.76816
ir	.5951238	.3156666	1.89	0.059	-.0235714	1.213819
ado	.6064745	.4649127	1.30	0.192	-.3047377	1.517687
ady	-1.160102	.2958196	-3.92	0.000	-1.739898	-.5803066
up	1.061042	7.132549	0.15	0.882	-12.9185	15.04058
unp	.1084107	.3111024	0.35	0.727	-.5013388	.7181602
_cons	-57.61983	489.9241	-0.12	0.906	-1017.853	902.6138

```
Warning: gmm two-step standard errors are biased; robust standard
         errors are recommended.
Instruments for differenced equation
        GMM-type: L(2/2).gds
        Standard: D.gdp D.inf D.ir D.ado D.ady D.up D.unp
Instruments for level equation
        Standard: _cons

. estat sargan
Sargan test of overidentifying restrictions
        H0: overidentifying restrictions are valid

        chi2(13)     =  3.641566
        Prob > chi2  =    0.9944
```

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Tablica 28: Arellano – Bondov procjenitelj u dva koraka, nezavisne endogene

```
. xtabond gds, noconstant lags(1) maxldep(1) twostep endog(gdp inf ir ado ady up unp, lagstruct(
> 0,1)) artests(2)

Arellano-Bond dynamic panel-data estimation  Number of obs         =        91
Group variable: zemljaid                     Number of groups      =        12
Time variable: godina
                                             Obs per group:    min =         1
                                                               avg =  7.583333
                                                               max =        14

Number of instruments =     85               Wald chi2(8)          =    348.09
                                             Prob > chi2           =    0.0000
Two-step results
```

gds	Coef.	Std. Err.	z	P>|z|	[95% Conf.	Interval]
gds						
L1.	.580415	.1810132	3.21	0.001	.2256356	.9351944
gdp	.2939114	.1079751	2.72	0.006	.0822842	.5055386
inf	.3402338	.4646665	0.73	0.464	-.5704958	1.250963
ir	.3274743	.2058026	1.59	0.112	-.0758915	.7308401
ado	.3876325	.7600651	0.51	0.610	-1.102068	1.877333
ady	-.8341516	.2114607	-3.94	0.000	-1.248607	-.4196963
up	-.403238	4.58167	-0.09	0.930	-9.383146	8.57667
unp	-.0320976	.3486023	-0.09	0.927	-.7153455	.6511503

```
Warning: gmm two-step standard errors are biased; robust standard
         errors are recommended.
Instruments for differenced equation
        GMM-type: L(2/2).gds L(2/2).gdp L(2/2).inf L(2/2).ir L(2/2).ado
                  L(2/2).ady L(2/2).up L(2/2).unp

. estat sargan
Sargan test of overidentifying restrictions
        H0: overidentifying restrictions are valid

        chi2(77)     =  5.159197
        Prob > chi2  =    1.0000
```

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Tablica 29: Blundell – Bondov (BB) procjenitelj u dva koraka

```
. xtdpdsys gds gdp inf ir ado ady up unp, noconstant lags(1) maxldep(1) twostep artests(2)

System dynamic panel-data estimation         Number of obs         =       103
Group variable: zemljaid                     Number of groups      =        12
Time variable: godina
                                             Obs per group:    min =         2
                                                               avg =  8.583333
                                                               max =        15

Number of instruments =     35               Wald chi2(8)          =  49530.76
                                             Prob > chi2           =    0.0000
Two-step results
```

gds	Coef.	Std. Err.	z	P>|z|	[95% Conf.	Interval]
gds						
L1.	.5476014	.2522161	2.17	0.030	.053267	1.041936
gdp	.3668847	.0946844	3.87	0.000	.1813067	.5524627
inf	.6785825	.4187919	1.62	0.105	-.1422346	1.4994
ir	.7873269	.4383801	1.80	0.072	-.0718824	1.646536
ado	.8302931	.4201664	1.98	0.048	.006782	1.653804
ady	-1.230026	.4671103	-2.63	0.008	-2.145546	-.3145067
up	-1.95375	2.50266	-0.78	0.435	-6.858874	2.951374
unp	-.1372411	.1920691	-0.71	0.475	-.5136896	.2392074

```
Warning: gmm two-step standard errors are biased; robust standard
         errors are recommended.
Instruments for differenced equation
        GMM-type: L(2/2).gds
        Standard: D.gdp D.inf D.ir D.ado D.ady D.up D.unp
Instruments for level equation
        GMM-type: LD.gds

. estat sargan
Sargan test of overidentifying restrictions
        H0: overidentifying restrictions are valid

        chi2(27)     =  2.726476
        Prob > chi2  =    1.0000
```

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Tablica 30: Blundell – Bondov (BB) procjenitelj u dva koraka, nezavisne endogene

```
. xtdpdsys gds, noconstant lags(1) maxldep(1) twostep endog(gdp inf ir ado ady up unp, lagstruct
> (0,1)) artests(2)

System dynamic panel-data estimation         Number of obs         =       103
Group variable: zemljaid                     Number of groups      =        12
Time variable: godina
                                             Obs per group:    min =         2
                                                               avg =  8.583333
                                                               max =        15

Number of instruments =    170               Wald chi2(8)          =  35472.62
                                             Prob > chi2           =    0.0000
Two-step results
```

gds	Coef.	Std. Err.	z	P>|z|	[95% Conf.	Interval]
gds						
L1.	.7202156	.2098502	3.43	0.001	.3089168	1.131514
gdp	.2734595	.0525251	5.21	0.000	.1705121	.3764068
inf	.4139938	.3326183	1.24	0.213	-.2379261	1.065914
ir	.3294572	.2154424	1.53	0.126	-.0928022	.7517166
ado	.3219246	.3381424	0.95	0.341	-.3408223	.9846714
ady	-.7478903	.435109	-1.72	0.086	-1.600688	.1049077
up	.1995945	.107327	1.86	0.063	-.0107625	.4099515
unp	-.0096787	.1590492	-0.06	0.951	-.3214093	.302052

```
Warning: gmm two-step standard errors are biased; robust standard
         errors are recommended.
Instruments for differenced equation
        GMM-type: L(2/2).gds L(2/2).gdp L(2/2).inf L(2/2).ir L(2/2).ado
                  L(2/2).ady L(2/2).up L(2/2).unp
Instruments for level equation
        GMM-type: LD.gds LD.gdp LD.inf LD.ir LD.ado LD.ady LD.up LD.unp

. estat sargan
Sargan test of overidentifying restrictions
        H0: overidentifying restrictions are valid

        chi2(162)    =  4.043417
        Prob > chi2  =    1.0000
```

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Tablica 31: Rezultati modela

	(AB) gds	(AB endogene) gds	(BB) gds	(BB endogene) gds
L.gds	0.572** (0.229)	0.580*** (0.181)	0.548** (0.252)	0.720*** (0.210)
gdp	0.351*** (0.0849)	0.294*** (0.108)	0.367*** (0.0947)	0.273*** (0.0525)
inf	0.804 (0.492)	0.340 (0.465)	0.679 (0.419)	0.414 (0.333)
ir	0.595* (0.316)	0.327 (0.206)	0.787* (0.438)	0.329 (0.215)
ado	0.606 (0.465)	0.388 (0.760)	0.830** (0.420)	0.322 (0.338)
ady	-1.160*** (0.296)	-0.834*** (0.211)	-1.230*** (0.467)	-0.748* (0.435)
up	1.061 (7.133)	-0.403 (4.582)	-1.954 (2.503)	0.200* (0.107)
unp	0.108 (0.311)	-0.0321 (0.349)	-0.137 (0.192)	-0.00968 (0.159)
_cons	-57.62 (489.9)			
N	91	91	103	103
R^2				

Standard errors in parentheses
* $p < 0.1$, ** $p < 0.05$, *** $p < 0.01$

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Tablica 32: LSDV i LSDVc(ab) procjenitelj; uključena varijabla kriza

```
. xtlsdvc gds gdp inf ir ado ady up unp kriza, first lsdv initial (ab) vcov (200)
Note: Bias correction initialized by Arellano and Bond estimator

Arellano-Bond dynamic panel-data estimation     Number of obs      =         91
Group variable: zemljaid                       Number of groups   =         12

                                               Wald chi2(.)       =          .

Time variable: godina                          Obs per group: min =          1
                                                              avg =   7.583333
                                                              max =         14

One-step results
```

D.gds	Coef.	Std. Err.	z	P>|z|	[95% Conf.	Interval]
gds						
LD.	.7111984	.0955568	7.44	0.000	.5239104	.8984863
gdp						
D1.	.2480667	.0432979	5.73	0.000	.1632044	.332929
inf						
D1.	.2705591	.0761377	3.55	0.000	.1213319	.4197862
ir						
D1.	.251667	.0679073	3.71	0.000	.1185711	.3847629
ado						
D1.	.3301823	.0853495	3.87	0.000	.1629004	.4974642
ady						
D1.	-.5869472	.1451818	-4.04	0.000	-.8714983	-.3023962
up						
D1.	.0976704	.1562287	0.63	0.532	-.2085322	.403873
unp						
D1.	.0794227	.0729409	1.09	0.276	-.0635389	.2223843
kriza						
D1.	-.6073015	.3978216	-1.53	0.127	-1.387017	.1724144

```
Sargan test of over-identifying restrictions:
         chi2(104) =     66.77     Prob > chi2 = 0.9983

Arellano-Bond test that average autocovariance in residuals of order 1 is 0:
         H0: no autocorrelation    z =  -3.64    Pr > z = 0.0003
Arellano-Bond test that average autocovariance in residuals of order 2 is 0:
         H0: no autocorrelation    z =  -0.14    Pr > z = 0.8913
LSDV dynamic regression
```

gds	Coef.	Std. Err.	z	P>|z|	[95% Conf.	Interval]
gds						
L1.	.7717051	.0798776	9.66	0.000	.6151479	.9282622
gdp	.2275015	.0448776	5.07	0.000	.1395429	.3154601
inf	.1870531	.0704315	2.66	0.008	.0490098	.3250964
ir	.1692307	.063973	2.65	0.008	.0438459	.2946156
ado	.2331607	.0754978	3.09	0.002	.0851878	.3811336
ady	-.5809584	.1371306	-4.24	0.000	-.8497294	-.3121875
up	.1545377	.1373556	1.13	0.261	-.1146743	.4237497
unp	.0978805	.0692737	1.41	0.158	-.0378935	.2336546
kriza	-.6640339	.400162	-1.66	0.097	-1.448337	.1202691

```
note: Bias correction up to order O(1/T)

LSDVC dynamic regression
(bootstrapped SE)
```

gds	Coef.	Std. Err.	z	P>|z|	[95% Conf.	Interval]
gds						
L1.	.8818854	.0831838	10.60	0.000	.7188482	1.044923
gdp	.2430159	.0438926	5.54	0.000	.1569879	.3290438
inf	.1753578	.0732222	2.39	0.017	.0318449	.3188707
ir	.1574656	.0639954	2.46	0.014	.0320369	.2828943
ado	.2044022	.086418	2.37	0.018	.0350261	.3737784
ady	-.4951508	.162125	-3.05	0.002	-.81291	-.1773916
up	.1428763	.1603424	0.89	0.373	-.171389	.4571415
unp	.1279443	.0655991	1.95	0.051	-.0006275	.2565161
kriza	-.5664268	.3772966	-1.50	0.133	-1.305915	.1730609

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

Tablica 33: LSDV i LSDVc(bb) procjenitelj; uključena varijabla kriza

```
. xtlsdvc gds gdp inf ir ado ady up unp kriza, first lsdv initial (bb) vcov (200)
Note: Bias correction initialized by Blundell and Bond estimator

Note: Blundell and Bond estimator is implemented through
      the user-written Stata command -xtabond2- by David Roodman,
      Center for Global Development, Washington, DC droodman@cgdev.org
Favoring space over speed. To switch, type or click on mata: mata set matafavor speed, perm.
Warning: Number of instruments may be large relative to number of observations.

Dynamic panel-data estimation, one-step system GMM
------------------------------------------------------------------------------
Group variable: zemljaid                        Number of obs      =       103
Time variable : godina                          Number of groups   =        12
Number of instruments = 78                      Obs per group: min =         2
Wald chi2(9)  =  51624.69                                      avg =      8.58
Prob > chi2   =     0.000                                      max =        15
------------------------------------------------------------------------------
         gds |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
         gds |
         L1. |   1.007609   .0314141    32.08   0.000     .9460387    1.06918
             |
         gdp |    .1863803   .0394976     4.72   0.000     .1089664    .2637943
         inf |    .0725232   .0528633     1.37   0.170    -.0310869    .1761333
          ir |    .0840067   .0511431     1.64   0.100    -.0162318    .1842453
         ado |    .0514916   .0289549     1.78   0.075     -.005259    .1082422
         ady |   -.239298   .0702043    -3.41   0.001    -.3768959   -.1017001
          up |    .0392173   .0204617     1.92   0.055    -.0008868    .0793215
         unp |    .0509214    .040901     1.24   0.213    -.0292431    .1310859
       kriza |   -.8597656   .4068674    -2.11   0.035    -1.657211   -.0623201
------------------------------------------------------------------------------
Instruments for first differences equation
  Standard
    D.(gdp inf ir ado ady up unp kriza)
  GMM-type (missing=0, separate instruments for each period unless collapsed)
    L(1/16).L.gds
Instruments for levels equation
  Standard
    gdp inf ir ado ady up unp kriza
  GMM-type (missing=0, separate instruments for each period unless collapsed)
    D.L.gds
------------------------------------------------------------------------------
Arellano-Bond test for AR(1) in first differences: z =  -3.70  Pr > z =  0.000
Arellano-Bond test for AR(2) in first differences: z =   0.10  Pr > z =  0.919
------------------------------------------------------------------------------
Sargan test of overid. restrictions: chi2(69)   =  81.90  Prob > chi2 =  0.137
  (Not robust, but not weakened by many instruments.)

Difference-in-Sargan tests of exogeneity of instrument subsets:
  GMM instruments for levels
    Sargan test excluding group:     chi2(57)   =  72.06  Prob > chi2 =  0.086
    Difference (null H = exogenous): chi2(12)   =   9.83  Prob > chi2 =  0.631
  iv(gdp inf ir ado ady up unp kriza)
    Sargan test excluding group:     chi2(61)   =  77.13  Prob > chi2 =  0.080
    Difference (null H = exogenous): chi2(8)    =   4.76  Prob > chi2 =  0.782

LSDV dynamic regression
------------------------------------------------------------------------------
         gds |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
         gds |
         L1. |   .7717051   .0798776     9.66   0.000     .6151479    .9282622
             |
         gdp |    .2275015   .0448776     5.07   0.000     .1395429    .3154601
         inf |    .1870531   .0704315     2.66   0.008     .0490098    .3250964
          ir |    .1692307    .063973     2.65   0.008     .0438459    .2946156
         ado |    .2331607   .0754978     3.09   0.002     .0851878    .3811336
         ady |   -.5809584   .1371306    -4.24   0.000    -.8497294   -.3121875
          up |    .1545377   .1373556     1.13   0.261    -.1146743    .4237497
         unp |    .0978805   .0692737     1.41   0.158    -.0378935    .2336546
       kriza |   -.6640339    .400162    -1.66   0.097    -1.448337    .1202691
------------------------------------------------------------------------------

note: Bias correction up to order O(1/T)

LSDVC dynamic regression
(bootstrapped SE)
------------------------------------------------------------------------------
         gds |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
         gds |
         L1. |   .9523378   .0779534    12.22   0.000     .7995519    1.105124
             |
         gdp |    .2507045   .0486107     5.16   0.000     .1554294    .3459797
         inf |    .1842758   .0812926     2.27   0.023     .0249451    .3436064
          ir |    .1573558   .0707146     2.23   0.026     .0187577    .2959538
         ado |    .2143002    .089851     2.39   0.017     .0381955    .3904048
         ady |   -.4410314   .1676117    -2.63   0.009    -.7695444   -.1125185
          up |    .1115413   .1742146     0.64   0.522    -.2299131    .4529957
         unp |    .1707932   .0737898     2.31   0.021     .0261678    .3154185
       kriza |   -.7008329   .4217983    -1.66   0.097    -1.527542    .1258765
------------------------------------------------------------------------------
```

Izvor: http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators [10.9.2017]; Prikaz autora

POPIS GRAFIKONA I TABLICA

Graf 1: Prosječna štednja kućanstva 30
Graf 2: Štednja kućanstva 31
Graf 3: Kamatna stopa na depozite 31
Graf 4: Omjer bruto duga i dohotka 31
Graf 5: Raspoloživi dohodak i podjela po krajnjoj upotrebi, razdoblje 2000. – 2007. godine 32
Graf 6: Raspoloživi dohodak i podjela po krajnjoj upotrebi, razdoblje 2008. – 2016. godine 32
Graf 7: Financijska imovina kućanstva, 2000. – 07 33
Graf 8: Financijska imovina kućanstva, 2008. – 16 33
Graf 9: Demografska struktura 33
Graf 10: Kretanje prosječne vrijednosti zavisne varijable, bruto domaće štednje 37
Graf 11: Kretanje prosječnih vrijednosti nezavisnih varijabli po godinama 38

Tablica 1: Varijable, mjere varijabli i očekivani predznak utjecaja 34
Tablica 2: Deskriptivna statistika zavisnih i nezavisnih varijabli 36
Tablica 3: Deskriptivna statistika zavisne varijable po zemljama 36
Tablica 4: Korelacijska matrica između nezavisnih varijabli 38
Tablica 5: Rezultati svih modela 39
Tablica 6: Sargan test, Arellano-Bondov (AB) procjenitelj u dva koraka 40
Tablica 7: Test autokorelacije reziduala 40
Tablica 8: Rezultati svih modela; uključena varijabla kriza 43
Tablica 9: Arellano-Bondov (AB) procjenitelj u dva koraka 53
Tablica 10: Sarganov test 53
Tablica 11: Blundell – Bondov (BB) procjenitelj u dva koraka 54
Tablica 12: LSDV procjenitelj 54
Tablica 13: LSDV i LSDVc(ab) procjenitelj 55
Tablica 14: LSDV i LSDVc(bb) procjenitelj 56
Tablica 15: Korigirani fiksni procjenitelj upotrebom ab procjenitelja 57
Tablica 16: Korigirani fiksni procjenitelj upotrebom ah procjenitelja 57
Tablica 17: Korigirani fiksni procjenitelj upotrebom bb procjenitelja 58
Tablica 18: Rezultati modela 58
Tablica 19: Korigirani fiksni procjenitelj upotrebom ab procjenitelja s lagiranim nezavisnim varijablama 59

Tablica 20: Korigirani fiksni procjenitelj upotrebom ah procjenitelja s lagiranim nezavisnim varijablama 59
Tablica 21: Korigirani fiksni procjenitelj upotrebom bb procjenitelja s lagiranim nezavisnim varijablama 60
Tablica 22: Rezultati modela 60
Tablica 23: Obični LSDV s lagiranim nezavisnim varijablama 61
Tablica 24: LSDV s lagiranim nezavisnim varijablama 62
Tablica 25: Rezultati modela 63
Tablica 26: Rezultati LSDV modela, korigiranog procjenitelja fiksnog efekta (LSDVc) i LSDVCa sa lagiranim varijablama 64
Tablica 27: Arellano – Bondov procjenitelj u dva koraka 65
Tablica 28: Arellano – Bondov procjenitelj u dva koraka, nezavisne endogene 66
Tablica 29: Blundell – Bondov (BB) procjenitelj u dva koraka 67
Tablica 30: Blundell – Bondov (BB) procjenitelj u dva koraka, nezavisne endogene 67
Tablica 31: Rezultati modela 68
Tablica 32: LSDV i LSDVc(ab) procjenitelj; uključena varijabla kriza 69
Tablica 33: LSDV i LSDVc(bb) procjenitelj; uključena varijabla kriza 70

SAŽETAK

Cilj istraživanja ovog diplomskog rada bio je ispitati utjecaj ekonomskih i demografskih determinanti na štednju kroz grupu 13 odabranih zemalja, članica EU, u razdoblju 2000. – 2016. godine. Istraživanje se provelo primjenom *panel analize*, a pregledom empirijskih istraživanja odabrane su varijable čiji se utjecaj na štednju ispituje i to: dohodak, inflacija, kamatna stopa, nezaposlenost, o hranitelju obitelji ovisne skupine i stupanj urbanizacije. Istraživanje se baziralo na *korigiranom procjenitelju fiksnog efekta*, a dobiveni rezultati su u skladu sa teorijskim pretpostavkama utjecaja varijabli na štednju. Pored navedenog osnovnog modela, razmatrao se utjecaj *financijske krize* za koju je potvrđen *negativan* utjecaj na štednju stanovništva u promatranoj grupi zemalja.

Ključne riječi: štednja, ekonomske i demografske determinante, financijska kriza, panel analiza, korigirani procjenitelj fiksnog efekta

SUMMARY

The aim of this master thesis was to examine the impact of economic and demographic determinants on savings through a group of 13 selected countries, an EU member, in the period 2000 - 2016. The research was carried out using a panel analysis, and by examining empirical research, variables were selected whose impact on savings is examined: income, inflation, interest rate, unemployment, family-dependent groups and urbanization degree. The research was based on a corrected estimator of fixed effect, and the obtained results are in accordance with the theoretical assumptions of the influences of variables on savings. In addition to the above-mentioned basic model, the impact of the financial crisis was considered. The crisis was confirmed to have a negative impact on population savings in the observed group of countries.

Keywords: savings, economic and demographic determinants, financial crisis, panel analysis, corrected estimate of fixed effect