Analiza utjecaja izabranih makroekonomskih varijabli na BDP Hrvatske

Domšić, Martina

Master's thesis / Diplomski rad

2018

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Pula / Sveučilište Jurja Dobrile u Puli**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:137:401181

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Image not found or type unknown

Repository / Repozitorij:

Digital Repository Juraj Dobrila University of Pula

zir.nsk.hr

Image not found or type unknown

Sveučilište Jurja Dobrile u Puli
Fakultet ekonomije i turizma
„Dr. Mijo Mirković“

MARTINA DOMŠIĆ

ANALIZA UTJECAJA IZABRANIH MAKROEKONOMSKIH VARIJABLI NA BDP HRVATSKE

Diplomski rad

Pula, 2018.

Sveučilište Jurja Dobrile u Puli
Fakultet ekonomije i turizma
„Dr. Mijo Mirković“

MARTINA DOMŠIĆ

ANALIZA UTJECAJA IZABRANIH MAKROEKONOMSKIH VARIJABLI NA BDP HRVATSKE

Diplomski rad

JMBAG: 0303047065, redoviti student
Studijski smjer: Ekonomija
Predmet: Makroekonomski management
Znanstveno područje: Društvene znanosti
Znanstveno polje: Ekonomija
Znanstvena grana: Makroekonomski management
Mentor: doc. dr. sc. Daniel Tomić

Pula, ožujak 2018.

IZJAVA O AKADEMSKOJ ČESTITOSTI

Ja, dolje potpisani _____, kandidat za magistra ekonomije/poslovne ekonomije ovime izjavljujem da je ovaj Diplomski rad rezultat isključivo mojega vlastitog rada, da se temelji na mojim istraživanjima te da se oslanja na objavljenu literaturu kao što to pokazuju korištene bilješke i bibliografija. Izjavljujem da niti jedan dio Diplomskog rada nije napisan na nedozvoljen način, odnosno da je prepisan iz kojega necitiranog rada, te da ikoji dio rada krši bilo čija autorska prava. Izjavljujem, također, da nijedan dio rada nije iskorišten za koji drugi rad pri bilo kojoj drugoj visokoškolskoj, znanstvenoj ili radnoj ustanovi.

Student

_____

U Puli, _____, _____ godine

IZJAVA

o korištenju autorskog djela

Ja, _____ dajem odobrenje Sveučilištu Jurja Dobrile
u Puli, kao nositelju prava iskorištavanja, da moj diplomski rad pod nazivom _____

_____

koristi na način da gore navedeno autorsko djelo, kao cjeloviti tekst trajno objavi u javnoj internetskoj bazi Sveučilišne knjižnice Sveučilišta Jurja Dobrile u Puli te kopira u javnu internetsku bazu završnih radova Nacionalne i sveučilišne knjižnice (stavljanje na raspolaganje javnosti), sve u skladu s Zakonom o autorskom pravu i drugim srodnim pravima i dobrom akademskom praksom, a radi promicanja otvorenoga, slobodnoga pristupa znanstvenim informacijama.

Za korištenje autorskog djela na gore navedeni način ne potražujem naknadu.

U Puli, _____ (datum)

Potpis

_____

KAZALO

1. UVOD 1

2. RELEVANTNE MAKROEKONOMSKE VARIJABLE 3

2.1. BRUTO DOMAĆI PROIZVOD 3

2.1.1. Komponente bruto domaćeg proizvoda 5

2.1.2. Razlika između realnog i nominalnog BDP-a i deflator BDP-a 7

2.2. OSOBNA POTROŠNJA 9

2.2.1. Odluka o potrošnji 10

2.2.2. Funkcija potrošnje 11

2.3. PLAĆE 13

2.4. REALNI EFEKTIVNI DEVIZNI TEČAJ 18

3. EMPIRIJSKA POZADINA 22

3.1. DOKAZI IZ SVIJETA 22

3.2. EMPIRIJSKI TEMELJ ZA REPUBLIKU HRVATSKU 25

4. EKONOMETRIJSKA ANALIZA VARIJABLI 29

4.1. POVEZANOST IZMEĐU VARIJABLI 29

4.2. OBILJEŽJA NEZAVISNIH VARIJABLI 30

4.2.1. Osobna potrošnja 30

4.2.2. Plaće 30

4.2.3. Realni efektivni devizni tečaj 31

4.3. PODACI 32

4.4. ODABIR LAGOVA I KOINTEGRACIJSKOG RANGA 35

4.5. KOINTEGRACIJA (DUGI ROK) 36

4.6. KRATKI ROK 39

4.7. DEKOMPOZICIJA VARIJANCI PROGNOSTIČKIH POGREŠAKA I IMPULSNE FUNKCIJE 40

4.8. REZULTATI ANALIZE MODELA 42

5. ZAKLJUČAK 44

LITERATURA 46

POPIS TABLICA 49

POPIS GRAFIKONA 50

PRILOZI 51

SAŽETAK 62

SUMMARY 63

1. UVOD

Bruto domaći proizvod složena je mjera ekonomske aktivnosti koji uključuje sve oblike potrošnje na domaće proizvedene robe i usluge. Stoga se BDP dijeli na četiri osnovne komponente: osobnu potrošnju (potrošnja kućanstva na robe i usluge.), investicijsku potrošnju, državnu potrošnju te neto izvoz. Plaću definiramo kao iznos novca, koji poslodavac, obično na mjesečnoj bazi, isplaćuje zaposleniku kao naknadu za obavljeni rad. Zakon o plaći propisuje način utvrđivanja visine plaće te način isplate i dr.. Realni (stvarni) efektivni devizni tečaj (u daljnjem tekstu REER) je mjera trgovinskog vaganog prosječnog tečaja valute prema košarici valute nakon prilagodbe razlika u inflaciji u odnosu na dotične zemlje iskazan kao indeksni broj u odnosu na baznu godinu.

Cilj ovog diplomskog rada je analiza utjecaja izabranih makroekonomskih varijabli na BDP Republike Hrvatske. Odnosno, cilj diplomskog rada je:

1. Analizirati utjecaj osobne potrošnje na realni bruto domaći proizvod Republike Hrvatske,
2. Analizirati utjecaj realnih bruto plaća na realni bruto domaći proizvod Republike Hrvatske te
3. Analizirati utjecaj realnog efektivnog deviznog tečaja na realni bruto domaći proizvod Republike Hrvatske.

Teorijska pozadina je krati uvod u daljnji dio rada koji se temelji na analizi varijabli (BDP, osobna potrošnja, plaće i REER), a cilj analize je prikazati utjecaj osobne potrošnje, realnih bruto plaća i REER-a (nezavisne varijable) na realni BDP (zavisna varijabla).

Nakon uvodnog poglavlja u kojem je naveden skraćeni prikaz pojedinog poglavlja ovog diplomskog rada, u drugom poglavlju je dan teorijski okvir o relevantnim makroekonomskim varijablama. Odnosno, u ovom poglavlju dana je teorijska pozadina o bruto domaćem proizvodu, osobnoj potrošnji, plaćama te realnom efektivnom deviznom tečaju. Ujedno u ovom poglavlju je dan prikaz makroekonomskih varijabli u Republici Hrvatskoj u razdoblju od 2000. do 2014. godine po kvartalima. Isti podaci se kasnije koriste u analizi izabranih makroekonomskih varijabli.

Iz prethodno navedenih ciljeva moguće je definirati tri osnovne hipoteze:

- H1: Povećanje osobne potrošnje utjecat će na povećanje realnog BDP-a Hrvatske,
- H2: Povećanje realnih bruto plaća utjecat će na smanjenje realnog BDP-a Hrvatske i
- H3: Deprecijacija tečaja hrvatske kune smanjit će realni BDP Hrvatske.

U trećem poglavlju diplomskog rada je dana empirijska pozadina kao uvod u daljnji dio diplomskog rada, analizu utjecaja osobne potrošnje, realnih bruto plaća i REER-a na realni BDP Republike Hrvatske. Četvrto poglavlje je analiza ekonometrijskog modela na prethodno spomenutim varijablama. Analiza varijabli se temelji na kvartalnim podacima u vremenskom razdoblju od 2000. do 2014. godine za Republiku Hrvatsku. Podaci su prikupljeni sa službenih stranica Državnog zavoda za statistiku i Hrvatske narodne banke. Ujedno, podaci su radi potrebe analize, vremenski desezonirani, te radi potrebe analize logaritmirani kako bi se isključio njihov sezonski karakter. Analiza varijabli je provedena u ekonometrijskom programu Gretl 2017d. U ovom dijelu rada će biti prikazan dugi (kointegracijski) te krati (VECM) rok, grafički prikaz varijabli, testovi kvalitete modela, kointegracijske veze između varijabli te odabir lagova. Svaki od pojedinih testova se nalaze u prilogu ovog diplomskog rada. Također, u ovom dijelu rada će se prikazati rezultati ove ekonometrijske analize. Posljednje poglavlje, peto, je zaključak ovog diplomskog rada.

Metode korištene prilikom izrade ovog diplomskog rada su istraživačka, matematička, statistička, metoda sinteze i analize, komparativna metoda, te deduktivan metoda. Tijekom pisanja je korištena znanstvena i stručna literatura (knjige, znanstveni članci te vjerodostojne Internet stranice).

Temeljem vjerodostojnih izvora i podataka, ovaj diplomski rad će dati odgovor na pitanje kojim intenzitetom odabrane makroekonomske varijable utječu na bruto domaći proizvod Republike Hrvatske.

2. RELEVANTNE MAKROEKONOMSKE VARIJABLE

2.1. BRUTO DOMAĆI PROIZVOD

Bruto domaći proizvod (BDP) definiramo kao tržišnu vrijednost svih finalnih roba i usluga proizvedenih u nekoj zemlji tijekom danog razdoblja. Sasvim očito je da je BDP vrlo složena mjera vrijednosti ekonomske aktivnosti. Kako bi se dobila potpunija slika stanja ekonomije jedne države postoji niz drugih parametara koji se izračunavaju. Neki od njih su bruto nacionalni proizvod (BNP), neto nacionalni proizvod (NNP), nacionalni dohodak, osobni dohodak, raspoloživi osobni dohodak (Mankiw, 2006).

Bruto nacionalni proizvod je ukupni dohodak koji su zaradili trajni rezidenti države, odnosno njeni državljani. Od BDP-a se razlikuje po tome što uključuje i onaj dohodak koji su naši državljani zaradili u inozemstvu, a isključuje dohodak koji su strani državljani zaradili u našoj zemlji. Neto nacionalni proizvod (NNP) je ukupan dohodak rezidenata određene države (BNP) koji je umanjen za gubitke nastale zbog amortizacije.

Sljedeći parametar koji se izračunava je nacionalni dohodak koji definiramo kao ukupni dohodak svih rezidenata određene države koji je zarađen proizvodnjom roba i usluga. Nacionalni dohodak uključuje subvencije, a ne uključuje posredno poslovno oporezivanje. Nadalje, parametar osobni dohodak ne obuhvaća zadržanu zaradu i isključuje odbitke od poreza na dobit i doprinose za socijalno osiguranje. Osobni dohodak obuhvaća dohodak kućanstva od kamata na državne obveznice i dohodak od transfera. Posljednji parametar je raspoloživi osobni dohodak koji obuhvaća dohodak kućanstva i obrta koji ostaje nakon podmirivanja svih obveza prema državi (porezi i druga davanja) (Mankiw, 2006).

Računi nacionalnog dohotka temelje se na ideji da se ekonomska aktivnost gospodarstva u određenom vremenu može mjeriti na tri načina: proizvodni pristup, potrošni pristup i dohodovni pristup. Proizvodni pristup mjeri ekonomsku aktivnost kao zbroj tržišnih vrijednosti svih konačnih proizvoda i usluga koji više ne ulaze u proces proizvodnje, već služe finalnoj potrošnji, a koji su proizvedeni u određenom razdoblju, uobičajeno u godini dana. U ovom se pristupu isključuju kupoprodaje dobara i usluga u međufaznoj proizvodnji.

Bruto domaći proizvod se može izračunati temeljem tri različita izračuna koji daju jedan rezultat: može se izračunati preko proizvodnje, preko dohotka i preko potrošnje. Postavlja se pitanje, zašto sva tri pristupa izračuna daju jednak rezultat? Prvo, kada promatramo ekonomiju kao cjelinu, možemo primijetiti da je ukupna potrošnja u gospodarstvu povezana s ukupnim dohotkom. Stoga, da bi se nešto moglo potrošiti potrebno je stvoriti određeni dohodak. Drugo, sve ono što se u ekonomiji proizvede to se i potroši. Prema tome, proizvodnja, potrošnja i dohodak su međusobno povezani te različitim pristupima mjere istu pojavu. Gotovo sve zemlje svijeta BDP računaju na isti način stoga su moguće međunarodne usporedbe. Vremenom, metodologija izračuna se mijenjala, u ovom radu naglasak je na hrvatskom BDP-u stoga valja napomenuti kako je aktualna metodologija prema kojoj se obračunava hrvatski BDP je Europski sustav nacionalnih računa ESA 2010 (Andabaka i dr., 2016).

Svaki od pristupa mjerenja BDP-a daje drugačiji pregled na gospodarstvo, a daju jednak rezultat. Stoga, proizvodni pristup mjeri ekonomsku aktivnost zbrajajući tržišne vrijednost svih finalnih proizvoda i usluga koji ne ulaze u daljnji proces proizvodnje, u određenom vremenskom razdoblju, najčešće jednoj godini. Finalnim dobrima smatramo ona dobra koja u namijenjena za potrošnju, dok intermedijarnim dobrima smatramo ona dobra koja se koriste kao input u proizvodnji. Tako primjerice, maslinovo ulje je primjer finalnog dobra koje ulazi u potrošnju, dok drvo iz hrvatskih šuma se koristi u proizvodnji i njega smatramo intermedijarnim dobrom. Također, u proizvodnom pristupu mjerenja BDP-a se isključuju kupoprodaje dobara i usluga u međufaznoj proizvodnji, tj. polazi se od koncepta dodane vrijednosti. Ekonomsku aktivnost mjerimo zbrajanjem dodanih vrijednosti svih proizvođača koje su jednake vrijednosti njihovog outputa koji je umanjen za vrijednost kupljenih inputa od drugih proizvođača. Sukladno metodologiji izračuna nacionalnog dohotka, kapitalna dobra (trajna dobra koja su proizvedena za proizvodnju drugih dobara) se klasificiraju kao finalna dobra pa se, ujedno, i njihova proizvodnja uključuje u BDP. Također, u BDP se uključuju i investicije u zalihe, a one se odnose na poluproizvode u proizvodnji te sirovi materijal. Kapitalna dobra i investicije u zalihe se uključuju u obračun BDP-a zbog njihovog povećanja proizvodnih mogućnosti u budućnosti. U sam obračun BDP-a nisu uključene aktivnosti „uradi sam“ (npr. kuhanje kod kuće ili bojanje zidova) te „podzemno gospodarstvo“ koje je neprijavljeno zbog poreza. Spomenute aktivnosti statistički zavodi procjenjuju te uključuju u BDP. Također, usluge države (npr. javno obrazovanje) nisu tržišno vrednovani pa se vrednuju prema troškovima proizvodnje i uključuju se u BDP.

Prema potrošnim pristupu izračuna BDP-a ekonomska aktivnost se mjeri zbrajanjem iznosa potrošnje krajnjih kupaca na kupnju roba i usluga. Odnosno, potrošni pristup izračuna BDP-a je zbroj osobne potrošnje (C), investicija (I), finalne državne potrošnje (G) i neto izvoza (X-IM), koji je razlika između uvoza i izvoza, u određenom vremenskom razdoblju, najčešće jednoj godini. Ovaj način izračuna možemo zapisati u obliku formule:

$$Y=C+I+G+(X-IM)$$

Potrošni izračun BDP-a osobna potrošnja, finalna državna potrošnja te investicije bilježe samo finalnu potrošnju dobara, a neto izvoz mjeri razmjenu finalnih i intermedijarnih dobara.

Posljednji pristup izračuna BDP-a je dohodovni izračun koji u obzir uzima dohotke primljene od proizvođača, ali i dohotke proizvođača (profit nakon odbitka poreza) i države (porezi). Odnosno, prema ovom izračunu BDP je zbroj svih primarnih dohodaka u gospodarstvu u određenom vremenskom razdoblju, najčešće jednoj godini. Primarnim dohotkom smatramo: plaće kao naknade za obavljeni rad, kamate kao naknade za kapital, rente kao naknade za zemljište i profite kao naknade za preuzeti rizik.

2.1.1. Komponente bruto domaćeg proizvoda

BDP uključuje sve oblike potrošnje na domaće proizvedene robe i usluge. Kako bi shvatili na koji način ekonomija koristi svoja oskudna sredstva ekonomisti često proučavaju različite vrste potrošnje koje čine sastavni dio BDP-a. U tu svrhu BDP (označen kao Y) dijele na četiri komponente: osobnu potrošnju (C), ulaganja ili investicijsku potrošnju (I), državnu potrošnju (G) i neto izvoz (NX) (Mankiw, 2006):

$$Y = C + I + G + NX$$

Prethodno je navedena jednadžba identiteta, odnosno jednadžba koja mora biti valjana zbog načina na koji su definirane njezine varijable.

Osobna potrošnja je potrošnja kućanstva na robe i usluge. „Robe“ uključuju potrošnju trajna dobra poput automobila i kućanskih aparata te potrošnju netrajnih dobara poput hrane i

odjeće. „Uslugama“ se smatraju neopipljiva dobra poput frizerskih i liječničkih usluga. Potrošnja kućanstva na obrazovanje također je dio potrošnje usluga (iako postoji opravdani argument da bi se takva vrsta potrošnje mogla ubrojiti u sljedeću komponentu, tj. u ulaganja ili investicijsku potrošnju) (Mankiw, 2006). „Primjer osobne potrošnje je kupnja hrane i pića ili automobila. Međutim, kada poduzetnik kupuje automobil koji će mu služiti, primjerice kao dostavno vozilo, tada se ta kupovina bilježi kao investicija. Ako država kupuje automobil za svoje službenike, tada se ta kupovina bilježi kao finalna državna potrošnja. Ako govorimo o slučaju Hrvatske koja nije proizvođač automobila, primijetite kako će sva tri automobila morati biti uvezena iz inozemstva te zbog toga neće povećati ukupan iznos BDP-a.“ (Andabaka i dr., 2016).

Ulaganje ili investicijsku potrošnju definiramo kao kupnju kapitalne opreme, zaliha i nekretnina koje će nam koristiti u budućnosti. Ulaganja u nekretnine uključuju i kupovanje novog stambenog prostora. Ukoliko kućanstva kupuju nekretninu, kupnja će se bilježiti kao investicije, a ne kao osobna potrošnja. Također, u makroekonomskom smislu kupovina financijskih instrumenata se neće bilježiti kao investicija. Na primjer, osoba M kupi obveznice poduzeća D. Tada poduzeće D taj novac ulaže u investicijsku opremu, u ovom slučaju riječ je o posudbi novčanih sredstava. Ukoliko bi se ulaganje u obveznice uračunavalo u investicije, u tom bi se slučaju sredstva dva puta obračunavala.

Državnom potrošnjom smatramo državne izdatke za robe i usluge mjesnih, državnih i saveznih vlasti. Ujedno uključuje i plaće državnih službenika kao i troškove javnih radova. Odnosno, u finalnu državnu potrošnju uključujemo tržišne i netržišne izdatke države. U tržišne izdatke se uključuju izdatci za lijekove, ortopedska pomagala te ostale proizvode koji su dostupni na tržištu. S druge strane, u netržišne izdatke ubrajamo usluge države koje ona pruža npr. obrazovanje, socijalna te zdravstvena skrb i sl..

Neto izvoz je posljednja komponenta bruto domaćeg proizvoda, a definiramo je kao razliku potrošnje stranaca na domaće proizvedenu robu (izvoz) i domaće potrošnje na stranu robu (uvoz). Pojam „neto“ unutar izraza „neto izvoz“ ukazuje na činjenicu da uvoz oduzimamo od izvoza i to zato što je uvoz roba i usluga sastavni dio nekih drugi komponenti BDP-a (Mankiw, 2006). Ovdje „izvoz predstavlja inozemnu potrošnju domaćih proizvoda, primjerice kada Nijemci kupuju Dorina čokoladu. Zbog toga se izvoz zbraja u ukupan iznos BDP-a i ima pozitivan predznak u jednadžbi BDP-a. Uvoz s druge strane predstavlja domaću potrošnju

inozemnih proizvoda i zato ima negativan predznak u jednadžbi BDP-a, primjerice kada Hrvati kupuju Milka čokoladu.“ (Andabaka i dr., 2016).

2.1.2. Razlika između realnog i nominalnog BDP-a i deflator BDP-a

Kada ekonomisti govore o BDP-u, u tom slučaju uglavnom govore o realnom BDP-u, a tek rijetko o nominalnom BDP-u. Nominalni BDP održava cijene i količine roba i usluga proizvedenih u određenoj ekonomiji. S druge strane, koristeći se stalnim cijenama, odnosno cijenama koje su prevladavale u baznoj godini, realni BDP održava samo količinu proizvedenih roba i usluga (Mankiw, 2006).

Problem kod nominalnog BDP-a je taj što se tijekom vremena količina dobara mijenja, ali i njihova cijena. Ekonomistima je važna samo realna promjena količine, a promjenu cijene žele isključiti. Postavlja se pitanje zašto je žele isključiti? Odgovor na ovo pitanje možemo dobiti kroz primjer recesije. U vrijeme recesije dolazi do pada proizvodnje, posljedično tome dolazi do rasta cijena. Ako je rast cijena veći od pada proizvodnje tada će nominalni BDP rasti, a realni BDP će padati. Upravo zbog toga, realni BDP je relevantnija mjera od nominalnog BDP-a.

Nominalni BDP se koristi za mjerenje ukupne aktivnosti u gospodarstvu u tekućim cijenama, ujedno opisuje i ukupnu razinu proizvodnje. Kako bi dobili vrijednost nominalnog BDP-a moramo zbrojiti proizvedene količine finalnih dobara i usluga te ih pomnožiti s njihovim tekućim cijenama. S obzirom da tekuće cijene nisu stalne nego se mijenjaju iz različitih razloga, nominalnim BDP-om se prikazuje kretanje realnog BDP-a, ali i kretanje cijena. Iz toga slijedi da se realni BDP izračunava tako da se iz nominalnog BDP-a isključi utjecaj kretanja cijena. Odnosno, realni BDP se dobiva inflacioniranjem ili deflacioniranjem nominalnog BDP-a pri čemu se BDP preračunava na stalne cijene.

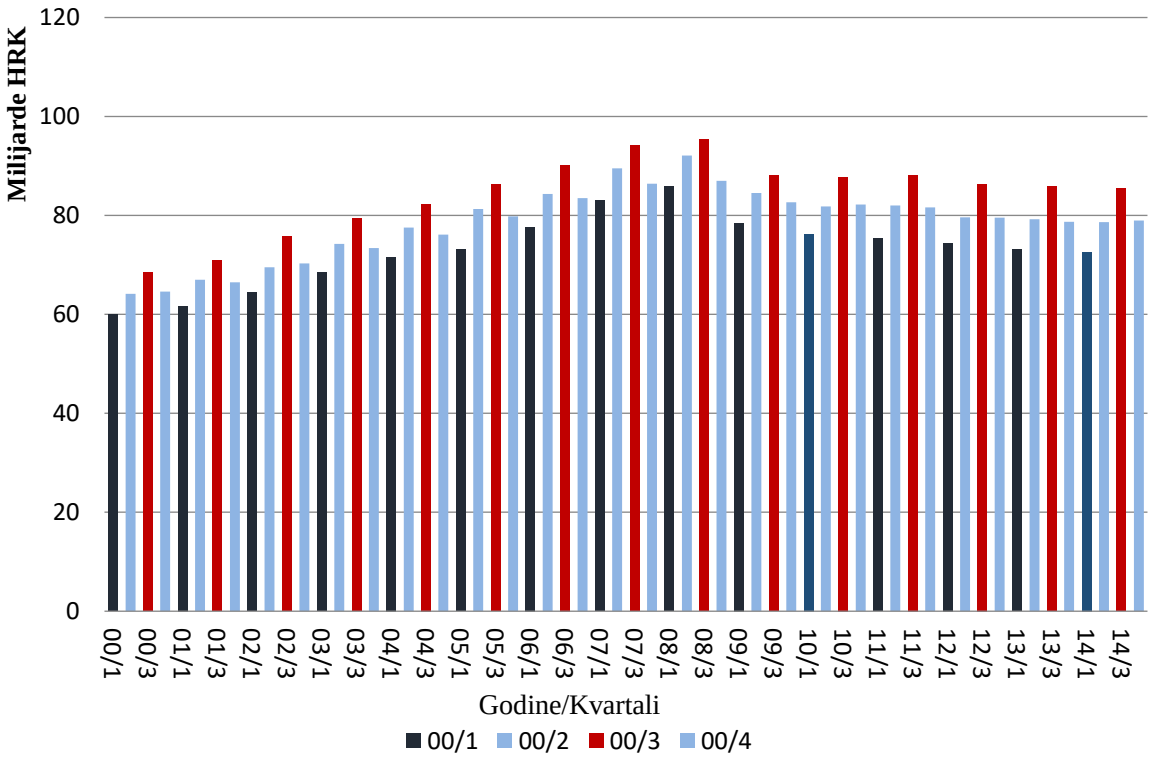
Prilikom obrade podataka, odnosno izračuna realnog BDP-a, statistički zavodi koriste verižne indekse s baznom godinom. Prilikom izračuna se koriste verižni indeksi, a ne bazne godine jer se koriste stalne cijene, a bazne godine se ažuriraju s time da ne dolazi do promjera stopa rasta BDP-a.

Koristeći se pokazateljima kao što su nominalni i realni BDP možemo izračunati treći pokazatelj koji nazivamo deflatorom BDP-a. Deflator BDP-a računamo tako da u omjer stavimo nominalni i realni BDP te pomnožimo sa sto što možemo napisati u obliku jednadžbe na sljedeći način (Mankiw, 2006):

$$\text{deflator BDP-a} = \frac{nominalni\ BDP}{realni\ BDP}\ X\ 100$$

Kod izračuna deflatora BDP-a nominalni i realni BDP su u baznoj godini isti stoga deflator BDP-a uvijek iznosi 100.

Grafikon 1. Realni BDP Republike Hrvatske u razdoblju od 2000./Q1 do 2014./Q4 u milijardama HRK



Izvor: Samostalan rad autorice prema podacima sa službene stranice Državnog zavoda za statistiku Republike Hrvatske.

Grafikon 1. prikazuje kretanje realnog bruto domaćeg proizvoda Republike Hrvatske u razdoblju od 2000./Q1 do 2014./Q4 u milijardama kuna. Iz grafikona možemo vidjeti trend smanjenja i povećanja realnog BDP-a u promatranom razdoblju. U promatranom razdoblju

realni BDP bilježi povećanje od gotovo 19 milijardi kuna (apsolutne vrijednosti se nalaze u prilogu 1.), u prvom kvartalu 2000. godine realni BDP je iznosio 60.002,44 milijuna kuna, a na kraju promatranog razdoblja, u četvrtom kvartalu 2014. godine iznosio je 78.969,93 milijuna kuna.

U 2008. godini, godini kada je Republiku Hrvatsku zahvatila svjetska ekonomska kriza, realni BDP bilježi najveću vrijednost u promatranom razdoblju i to u trećem kvartalu kada je iznosio 95.403,24 milijuna kuna. Nakon ovog razdoblja realni BDP bilježi smanjenja sve do kraja promatranog razdoblja. Analitičari RBA (Raiffeisen BANK) navode kako je za ovaj rast realnog BDP najviše utjecao snažan rast kapitalnih ulaganja u prvoj polovici godine (Raiffeisen BANK, 2017).

Promatrajući realni BDP kroz kvartale, vidimo da u trećem kvartalu realni BDP bilježi najveće vrijednosti. Razlog tome je što se treći kvartal odnosi na ljetne mjesece kada je turistička sezona te turistička potrošnja uvelike doprinosi povećanju realnog BDP-a. U ostalim kvartalima realni BDP bilježi smanjenje u odnosu na treći kvartal. Razlog tome što se ostali kvartali odnose na zimske mjesece kada nema značajnih aktivnosti koje bi utjecale na rast realnog BDP-a.

2.2. OSOBNA POTROŠNJA

Potrošači su bitni zbog toga što osobna potrošnja čini čak i do dvije trećine BDP-a. Ako se poveća dohodak potrošača oni će donijeti odluku kako će raspolagati sa svojim dohotkom. Odnosno jedan dio dohotka će potrošiti, a drugi dio će uštedjeti. Dio koji će biti potrošen postat će prihod za nekog drugog tko će ponovno trošiti i štedjeti. Takav proces se ponavlja, a učinak multiplikatora poboljšava situaciju za sve ako se rast potrošnje prelijeva u povećanje proizvodnje, a ne u više cijene. Istodobno, onaj dio uštođenog dohotka potrošača će osigurati financijska sredstva za ulaganje, što je bitno za buduću proizvodnju, prihod, ali i potrošnju.

Osobni dohodak je potrošen ili je ušteđen. Osobnim dohotkom smatramo tekući dohodak pojedinca iz svih izvora. Samu jezgru osobnog dohotka čine plaće i nadnice, te ukupan iznos pokriva i najamnine, kamatu i dividende, tekuće prijenose (beneficije od socijalnog osiguranja isplaćene osobama te poslove donacije dobrotvornim organizacijama). Nakon što se od osobnog dohotka oduzmu direktni porezi te razne naknade (npr. naknada za putovanje) i

tekući transferi u inozemstvu dobivamo osobni dohodak na raspolaganju. Stvarni osobni dohodak i osobni dohodak na raspolaganju su prihodi koji su usklađeni s inflacijom. Ukoliko nije dostupan niti jedan drugi pokazatelj deflacije, mogu biti upotrijebljene i potrošačke cijene.

2.2.1. Odluka o potrošnji

Odluka o potrošnji je povezana s odlukama o štednji. Mlada i stara kućanstva obično troše svoj prihod, dok sredovječna štede za mirovinu. Uz to, kućanstva naginju tome da posegnu u štednju ili se zaduže, kako bi održali potrošnju tijekom recesije (raspoređujući potrošnju tijekom života) (Stutely, 2007).

Glavni utjecaj na stupanj potrošnje imaju (Stutely, 2007):

1. prihodi,
2. očekivanja cijene,
3. kamatne stope,
4. potrošački kredit,
5. bogatstvo,
6. stanje zaliha i cijena dugotrajne imovine te
7. socijalni čimbenici.

AD 1. što su osobni prihodi veći to je veća i osobna potrošnja. Na prihode utječe kretanje gospodarskih ciklusa, glavne komponente prihoda su: prihodi od zapošljavanja, prihodi od samozapošljavanja, porezi, beneficije te kamate i dividende. Prihodi od zapošljavanja imaju glavi utjecaj na osobni dohodak. Njihov ukupni iznos ovisi o broju zaposlenih, odrađenim satima rada te o plaći. Sljedeća komponenta osobnog dohotka na raspolaganju su prihodi od samozapošljavanja, a povezani su s cjelokupnim gospodarstvom. Prihodi od samozapošljavanja će se povećati kada se poveća i nominalni BDP. Nadalje, dividende su osjetljive na dobit društva, a ujedno i stanje u gospodarstvu ima značajan utjecaj na njih. Plaćanje kamata kreće se u skladu s kamatnim stopama. Odnosno, ako je zaduživanje povezano sa štednjom, porast kamatnih stopa može uzrokovati pad neto prihoda od kamata. Dok, općenito, povećanje kamata poboljšava osobi dohodak na raspolaganju.

AD 2. tijekom velike inflacije potrošači nastoje što je moguće više uštedjeti, ali i manje potrošiti. Ukoliko potrošači očekuju jednokratno povećanje cijena zbog inflacije ili više indirektne poreze oni mogu prebaciti potrošnju na sljedeće razdoblje.

AD 3. što su kamatne stope više to će povećavati trošak postojećih zajmova i neće poticati na zaduživanje, već će se prije poticati štednja što će se odraziti na potiskivanje potrošnje. Ipak, više kamatne stope redistribuiraju prihod od mladih ljudi koji plaćaju hipoteke njihovim starijim generacijama, čiji su depoziti veći od zaduženja i koji mogu potrošiti dodatni prihod od kamata (Stutely, 2007).

AD 4. jednostavniji uvjeti dobivanja potrošačkih kredita potiče zaduživanje, a posljedično tome dolazi do povećanja potrošnje.

AD 5. ukoliko se vrijednost imovine poveća (cijena dionica i kuća) potrošači se osjećaju bogatije te se povećava njihova sklonost potrošnji.

AD 6. posjedovanjem dugotrajne imovine (automobil, električni uređaji i sl.) potrošači se osjećaju bogatijima. Ipak, ukoliko dođe do smanjenja cijena dugotrajne imovine ili ograničenja nabave iste izazvat će se privremeni potrošački bum.

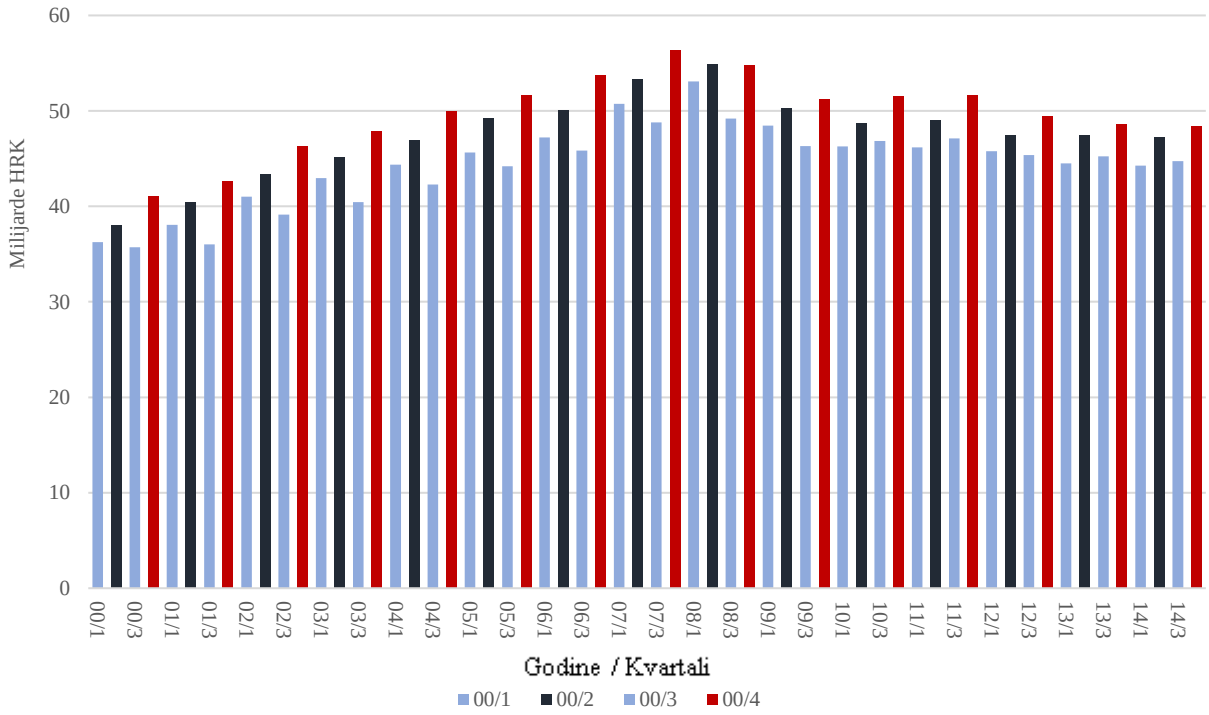
AD 7. socijalni čimbenici mogu potaknuti štednju koja bi mogla utjecati na oporučno ostavljanje imovine ili na potrošnju u mirovini.

2.2.2. Funkcija potrošnje

Prema Babić (2004), pod pretpostavkom da postoji gospodarstvo koje se sastoji samo od aktivnosti proizvodnje i potrošnje u tom se gospodarstvu potroši onoliko koliko se proizvodi, pa je proizvodnja jednaka dohotku. U takvoj situaciji gospodarstvo se nalazi u makroekonomskoj ravnoteži, pa će i agregatna ponuda uvijek biti jednaka agregatnoj potražnji. U situaciji kad bi se cjelokupna proizvodnja trošila u tekućoj potrošnji uzrokovala bi se stagnacija te ne bi postojala mogućnost bilo kakvog gospodarskog rasta. Razlog stagnacije je taj što se ništa ne odvaja za štednju koja je, znamo, izvor sredstava za financiranje investicija koje su pokretač gospodarskog rasta.

Ujedno, Babić (2004) pretpostavlja da se čitava proizvodnja ne potroši u tekućoj potrošnji, nego da se jedan dio proizvodnje akumulira radi razvoja i povećanja buduće potrošnje. Na taj se način agregatna potražnja dijeli na dvije komponente: osobnu i investicijsku potrošnju. Ovakvim makroekonomskim modelom se istražuje međuovisnost domaćeg proizvoda (agregatne ponude) i pojedinih komponenti agregatne potražnje (osobne potrošnje i investicija) da bi se objasnila kako promjena pojedinih komponenti agregatne potražnje djeluje na agregatnu ponudu i obrnuto. Pod pretpostavkom da će doći do povećanja dohotka to će rezultirati i povećanjem potrošnje zbog veće kupovne moći pojedinca. Također, pod ovom pretpostavkom potrošnja je neovisna o dohotku zbog toga što pojedinci moraju zadovoljiti vlastite potrebe (hrana, odjeća i sl.).

Grafikon 2. Osobna potrošnja u Republici Hrvatskoj u razdoblju od 2000./Q1 do 2014./Q4 u milijardama HRK



Izvor: Samostalan rad autorice prema podacima sa sužbene stranice Državnog zavoda za statistiku Republike Hrvatske.

Grafikon 2. prikazuje osobnu potrošnju u Republici Hrvatskoj u razdoblju od 2000./Q1 do 2014./Q4 u milijardama kuna (apsolutne vrijednosti osobne potrošnje se nalaze u prilogu 1.). U promatranom razdoblju osobna potrošnja bilježi povećanje od 12.104,86 milijuna kuna (u 2000./Q1 iznosila je 36.242,93 milijuna kuna, a u 2014./Q4 iznosi 48.347,79 milijuna kuna).

Osobna potrošnja, kao i realni BDP, u 2008. i 2009. godini bilježi znatno povećanje unatoč činjenici da je ovih godina Republiku Hrvatsku zahvatila svjetska ekonomska kriza. Pa tako, osobna potrošnja u 2008. godini u četvrtom kvartalu bilježi najveći porast te iznosi 54.743,08 milijuna kuna, dok u istom kvartalu 2009. godine je bilježi smanjenje u odnosu na prethodnu godinu te iznosi 51.236,37 milijuna kuna. Upravo, u navedenim kvartalima osobna potrošnja je imala najveće vrijednosti koje se do kraja promatranog razdoblja smanjuju. Iako se smatra da u Hrvatskoj nije prisutna svjetska ekonomska kriza, osobna potrošnja još uvijek nije na razni osobne potrošnje iz 2008. godine.

Ukoliko promatramo osobnu potrošnju kroz kvartale vidljivo je da je u četvrtom kvartalu osobna potrošnja bilježi najveće vrijednosti kao i u drugom kvartalu u kojem su ipak te vrijednosti nešto manje nego u četvrtom kvartalu. Dok u prvom i trećem kvartalu, osobna potrošnja u promatranom razdoblju je znatno manja u odnosu na drugi i četvrti kvartal. Potencijalni razlozi za ovakvo ponašanje osobne potrošnje kroz kvartale su ti što su u četvrtom i drugom kvartalu blagdani, Božić, Nova godina, Uskrs, te su potrošači u ovim mjesecima skloniji većoj kupovini blagdanskih namirnica te prigodnih poklona za svoju obitelj i prijatelje.

2.3. PLAĆE

Stutely (2007) definira različite pojmove vezane uz plaće, zarade i troškove radne snage. Pa tako definira stopu plaće kao osnovu plaću po razdoblju (sat, tjedan itd.). Ujedno, definira zaradu kao osnovnu plaću plus prekovremeni sati i bonusi. Troškovima radne snage, ponekad ih nazivamo ukupnom kompenzacijom, smatramo nadnice i plaće plus doprinosi za mirovinsko osiguranje, porez na platnu listu (socijalno osiguranje, besplatan obrok i druge pogodnosti). Također, promjene plaća definira kao tendenciju da zarade brže rastu od stope plaća zbog prekovremenog rada te bonusa.

Plaća je naknada koju isplaćuje poslodavac zaposleniku. Može biti izračunata kao fiksni iznos ili prema količini određenog posla. Plaća predstavlja iznos koji radnici ostvaruju u svom radnom odnosu za svoj rad za određeno razdoblje (mjesec, tjedan, dan). Za radnika i njegovu obitelj plaće su najčešći dominantni izvor sredstava za život, koji uz to radniku donosi osjećaj korisnosti ili vrijednosti. S druge strane, plaće su trošak poslovanja poslodavca i to vrlo

značajan trošak po svom opsegu. Takva dvojnost plaća dovodi do različitih stava u ocjeni njihove uloge, dinamike i apsolutne veličine. Radnici i sindikati ponajprije promatraju neto plaće, dok poslodavci govore o ukupnom trošku rada, odnosno bruto plaći. (Bušelić, 2017)

Ovisno o strukturi pojedinog gospodarstva, na razinu plaće uvelike će utjecati tržišne snage, odnosno ponude i potražnje, zakonodavstvo i tradicija. Plaće su osnovni i jedini dohodak od nesamostalnog rada za većinu radnika. Stoga određivanje plaća i utvrđivanje prava i obveza koje proizlaze iz radnog odnosa imaja posebnu važnost. Kod određivanja plaća visoka je ovisnost o kapitalnoj opremljenosti, motivaciji radnika, o samom mjestu gdje oni rade i o razini njihove efikasnosti. Stoga, u tržišnim gospodarstvima postoje razni poticaji koji omogućavaju uspješniju alokaciju proizvodnih resursa i učinkovitije poslovanje uz što manje državne intervencije. Sami procesi na tržištu određuju strukturu i korištenje poticaja te poslovni subjekti sami odlučuju o svom poslovanju u skladu s prilikama na tržištu i sukladno tome određuju i plaće radnika. Suprotno tome, kod planskog gospodarstva na tržište se uvelike vrši utjecaj kroz administrativne odluke i socijalne pritiske od strane države koja određuje kako i koliko zapošljavati, a time i razinu plaće. U takvom gospodarstvu, razina plaća nije usklađena s proizvodnošću i radnom efikasnošću (Bušelić, 2017).

Kada se govori o određivanju plaća gotovo uvijek treba spomenuti i njihovu fleksibilnost. Neoklasična teorija prepoznaje sva uzroka njihove (ne) fleksibilnosti. Prvi uzrok su egzogenog karaktera, a odnose se na vanjske pritiske koji ometaju slobodno funkcioniranje tržišta (utjecaj države i djelovanje sindikata). Drugi uzroci su endogenog karaktera te iz njih proizlazi da je jedan od uzroka nefleksibilnosti posljedica optimizacije odnosa između radnika i poslodavaca te same efikasnosti nadnica.

Adam Smith uočio je pet razloga zbog kojih postoje razlike u najamninama između različitih poslova odnosno naknadama za obavljeni rad isključivo radnika i time postavio teoriju čistih prednosti koja se zapravo zasniva na prednostima koje nisu izravno vezane uz zaradu i nedostatke različitih poslova. Prvi je razlog nazvao prijatnost posla pod kojim je mislio na prirodu radnog okruženja. Prijatnost posla određuje mnogo čimbenika. Među njima su sigurnost i urednost radnog mjesta, prijateljsko okruženje te unutarnje zadovoljstvo koje pruža sam posao. Ovi se čimbenici smatraju najvažnijima. Stoga se pretpostavlja da će radnik koji obavlja posao u nesigurnim i prljavim uvjetima biti plaćen više od onoga koji radi na sigurnom i čistom mjestu. Drugi razlog za razlike u plaći uočio je u trošku obuke. Dakle,

nadnica će biti veća za poslove koji traže visok stupanj vještina, znanja i obrazovanja. Treće, Smith smatra ako postoje razlike u nadnicama zbog različite dužine trajanja zaposlenja. Napose naglašava problematiku sezonskih poslova ili one poslove u kojima su česta otpuštanja i zapošljavanja na kraće vrijeme. Stoga bi i takvi poslovi trebali biti plaćeni više od onih stabilnijih (Bušelić, 2017).

Prema Zakonu o radu (NN 127/17) poslodavac je dužan radniku obračunati i isplatiti plaću u iznosu utvrđenom propisom, kolektivnim ugovorom, pravilnikom o radu, odnosno ugovorom o radu. Ukoliko, osnove i mjerila za isplatu plaće nisu uređeni kolektivnim ugovorom, poslodavac koji zapošljava najmanje dvadeset radnika dužan ih je utvrditi pravilnikom o radu. Ako plaća nije određena niti jednim od prethodno spomenutim ugovora onda se isplaćuje plaća koju odredi sud prema okolnostima slučaja.

Zakon o radu (NN/127/17) propisuje isplatu plaće i naknadu plaće. Propisuje da se plaća isplaćuje nakon obavljenog rada te se isplaćuje u novcu, osim ako kolektivnim ugovorom ili ugovorom o radu drugačije nije određeno. Plaća i naknada plaće za prethodni mjesec se isplaćuju najkasnije do petnaestog dana sljedećeg mjeseca. Poslodavac je dužan, najkasnije petnaest dana od dana isplate plaće, naknade plaće ili otpremnine, radniku dostaviti obračun iz kojeg je vidljivo kako su ti iznosi utvrđeni. Ukoliko poslodavac u cijelosti ne isplati plaću, naknadu plaće ili otpremninu na dan dospjelosti, dužan je do kraja mjeseca u kojem je dospjela isplata plaće, naknada plaće ili otpremnine, radniku dostaviti obračun iznosa koje je bio dužan isplatiti.

Ukoliko je radno mjesto specifično, odnosno sadrži otežane uvjete rada ili sadrži prekovremeni te noćni rad, ali i rad nedjeljom, blagdanom ili drugim danom koji je određen kao slobodan, radnim prema Zakonu ima pravo na povećanu plaću.

Postoje razdoblja u kojima se zbog opravdanih razloga ne radi (razdoblja su određena zakonom, drugim propisom, kolektivnim ugovorom, pravilnikom o radu ili ugovorom o radu), za ta razdoblja radnik ima pravo na naknadu plaće. Također, prema Zakonu o radu (NN 127/17) radnik ima pravo na naknadu plaće za vrijeme prekida rada do kojeg je došlo krivnjom poslodavaca ili zbog drugih okolnosti za koje radnik nije odgovoran. Ujedno, onaj radnik koji odbije raditi zbog neprovedenih mjera zaštite zdravlja i sigurnosti na radu, ima

pravo na naknadu plaće za vrijeme dok se ne provedu propisane mjere zaštite zdravlja i sigurnosti na radu.

Kada govorimo o strukturi plaće, onda plaću promatramo kroz tri dijela: osnovu plaće, dodatka na plaću i stimulativni ili varijabilni dio. Osnovna plaća se isplaćuje za redoviti rad za puno radno vrijeme te prosječne rezultate rada. Na visinu osnovne plaće mogu utjecati složenost pojedinog radnog mjesta, uvjeti rada i slično. Također, na visinu osnovne plaće može utjecati opseg posla, izvršenje plana te sama kvaliteta izvršenja radnih zadataka. Dodaci na plaću najčešće se utvrđuju ukoliko na pojedinim radnim mjestima postoje posebni uvjeti rada. Posebnim uvjetima rada smatramo: uvjete za rad koji su teži od uobičajenih, obavljanje rada nakon proteka radnog vremena, rad blagdanima i neradnim danima i drugo. Stimulativnim dijelom plaće najčešće se podrazumijeva nagrađivanje za postignute rezultate rada (nove aktivnosti, sudjelovanje u projektima). Ovdje se pojavljuje problem kod utvrđivanja kriterija koji će utjecati na visinu stimulacije, tj. ocjenu doprinosa pojedinog radnika.

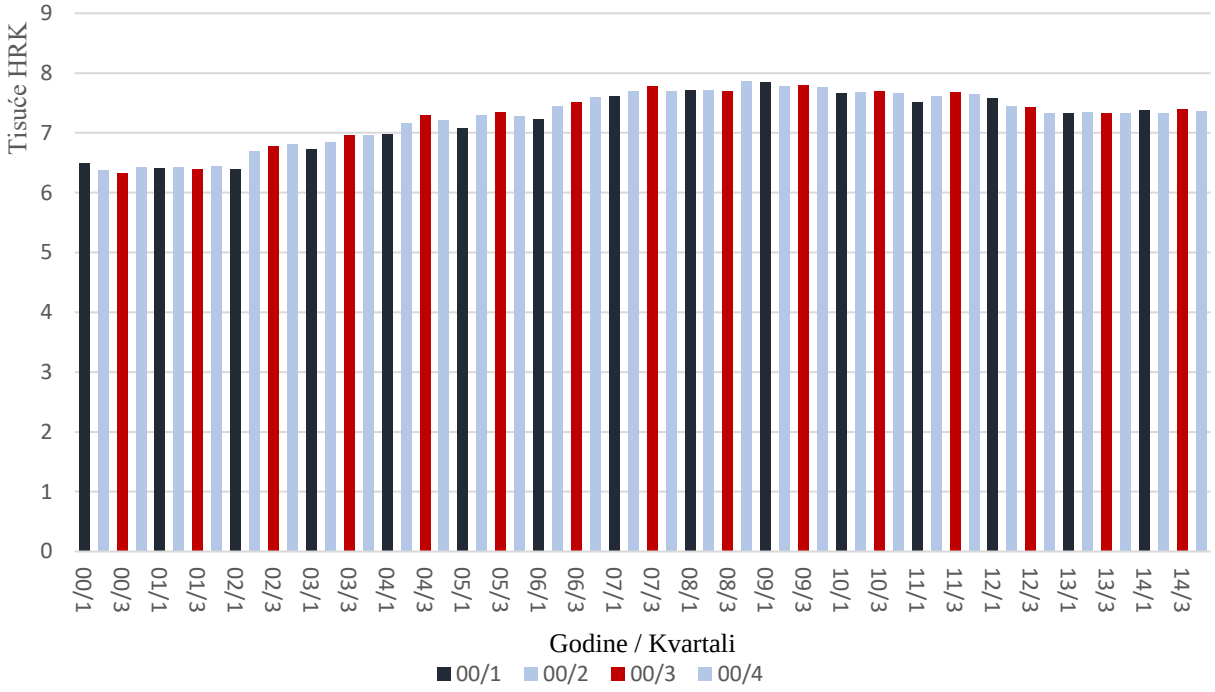
Doprinosi za obvezna osiguranja radnika određeni su propisima u dijelu osnovica i dijelu stopa koje se primjenjuju na određenu osnovicu. Doprinosi se obračunavaju na bruto plaću radnika. Obračunavanjem doprinosa radnika znači da radnik ostvaruje plaću u bruto iznosu i snosi dio obveza iz plaće. Stope doprinosa iz plaće su one koje se odnose na mirovinsko osiguranje, i to na: temelju individualne kapitaliziranje štednje (tzv. II. Stup), temelju generacijske solidarnosti (tzv. I. Stup) i u slučaju da se radnik nije mogao ili mora opredijeliti za II. Mirovinski stup, mirovina se obračunava samo na osnovi generacijske solidarnosti. Obračunavanje doprinosa na plaću obveza je poslodavca, a bruto plaća je osnovica za obračun tih doprinosa. Doprinosi na plaću su: osnovno zdravstveno osiguranje, poseban doprinos za zdravstveno osiguranje za prava u slučaju ozljede na radu i profesionalne bolesti i za zapošljavanje iz doprinosa koje izdvaja poslodavac u fondove za svakog radnika, financiraju se potrebe ostalih građana na načelu generacijske solidarnosti (Bušelić, 2017).

Plaće i zarade su usko povezane s gospodarskim ciklusom. Kada se ukupna potražnja počne oporavljati nakon recesije, proizvođači odmah odgovaraju povećanjem prekovremenog rada, a zarade rastu brže od plaća. Tek kad se ustali pojačana potražnja, poslodavci zapošljavaju više radnika, što čini daljnji pritisak na povećanje plaća. Kad se ciklus okrene, i output počne padati, prvo se smanjuje prekovremeni rad, a zarada raste manje rapidno ili pada. Onda dolazi

do otpuštanja radnika. Godišnje povećanje stopa plaća obično se smanjuje ako raste nezaposlenost, iako s odgodom (Stutely, 2007).

Ako zarade rastu brže od inflacije potrošačkih cijena, raste stvarna potrošačka moć. Ovdje treba naglasiti da postoji mogućnost korekcije podataka o zaradama zbog sukoba u industriji, jednokratnih uplata zaostalih plaća, privremenih otpuštanja radnika tijekom lošeg razdoblja i sl.

Grafikon 3. Realne bruto plaće u Republici Hrvatskoj u razdoblju od 2000./Q1 do 2014./Q4 u tisućama HRK



Izvor: Samostalan rad autorice prema podacima sa službene stranice Državnog zavoda za statistiku Republike Hrvatske.

Grafikon 3. prikazuje realne bruto plaće u Republici Hrvatskoj za razdoblje od 2000./Q1 do 2014./Q4 u tisućama kuna (apsolutne vrijednosti realnih bruto plaća se nalaze u prilogu 1.). U 2000. godini u prvom kvartalu realne bruto plaće su iznosile 6.500,19 kuna, a u četvrtom kvartalu 2014. godine iznose 7.363,81 kunu, što je povećanje realnih bruto plaća u promatranom razdoblju za 863,62 kune.

U četvrtom kvartalu 2008. godine realne bruto plaće su iznosile 7.874,38 kuna, upravo u rovom razdoblju bruto realne plaće u Hrvatskoj su bile najveće. Poslije ovog kvartala događa se smanjenje realnih bruto plaća te se upravo 2008. godina smatra posljednjom godinom kada su plaće rasle do navedenog iznosa jer nakon spomenute godine je uslijedilo razdoblje svjetske ekonomske krize koja je imala negativan utjecaj na sve makroekonomske pokazatelje, pa tako i na plaće.

Promatramo li realne bruto plaće kroz kvartale, vidimo da se različito ponašaju kroz pojedine kvartale, no razlika u plaćama kroz kvartale je zanemariva. Treći kvartal se ističe po visini bruto realne plaće te su u ovom kvartalu one najveće.

2.4. REALNI EFEKTIVNI DEVIZNI TEČAJ

Potraživanja u stranoj valuti smatramo devizama. Prema tome, devizni tečaj definiramo kao cijenu jedne jedinice strane valute koja je izražena brojem jedinica domaće valute. Drugim riječima, devizni tečaj pokazuje koliko je jedinica domaće valute potrebno platiti za jednu jedinicu strane valute. Primjerice, za jedan američki dolar potrebno je izdvojiti 5,84 kuna. Deviznim tečajem smatramo cijenu koju plaćamo kod kupovine strane valute. Primjerice, ukoliko uvoznik L iz zemlje H uvesti robu iz zemlje G, on mora kupiti ne samo tu robu nego, u valutu zemlje G, kojoj će robu platiti. Isto vrijedi i za uvoznika iz zemlje G (Babić i Babić, 2003).

Razlikujemo tri moguća načina određivanja deviznih tečajeva u nacionalnom gospodarstvu: fiksni, fleksibilni i kontrolirani (prljavi) tečajevi. Svaki od navedenih sustava određivanja deviznih tečajevima ima svoje prednosti i nedostatke. Odluku o primjeni mehanizma određivanja tečajeva donosi monetarna vlast pri tome mora voditi računa o veličini gospodarstva, otvorenosti gospodarstva, stopi inflacije, međunarodnim financijskom tokovima i sl.

S obzirom da je u ovom diplomskom radu naglasak na realnom deviznom tečaju koji je dio sustava fluktuirajućeg tečaja u nastavku teksta definirat ćemo pojmove nominalnog, realnog i efektivnog deviznog tečaja. U svom radu Perišin, Šokman i Lovrinović (2001) nominalni devizni tečaj definiraju kao tečaj koji predstavlja promjenu cijene domaće valute, izražena u stranoj valuti, zanemarujući pri tome stopu inflacije. Dok realni devizni tečaj je onaj tečaj koji

je korigiran za stopu inflacije. Korekcijom nominalnog tečaja za stopu inflacije prikazujemo relevantnu sliku kupovne moći domaće valute.

Realni (stvarni) efektivni devizni tečaj (u daljnjem tekstu REER) je mjera trgovinskog vaganog prosječnog tečaja valute prema košarici valute nakon prilagodbe razlika u inflaciji u odnosu na dotične zemlje iskazan kao indeksni broj u odnosu na baznu godinu.

Kako bismo bolje shvatili značenje REER-a, definirat ćemo i što je nominalni devizni tečaj (u daljnjem tekstu NEER). Nominalni devizni tečaj je mjera vrijednosti valute prema ponderiranom prosjeku s nekoliko stranih valuta. NEER se mjeri nominalnim vrijednostima, odnosno ne uzima u obzir razlike između kupovne moći dvije valute. Nasuprot NEER-a je REER, koji u odnosu na NEER u obzir uzima indekse cijena i njihove trendove. Prema tome, REER je NEER s uklonjenom inflacijom cijena ili troškova rada. Stoga, REER koristimo u usporedbama brojnih zemalja jer može pokazati koji dio su stekle te koji dio su izgubile u njihovoj međunarodnoj konkurentnosti.

NEER omogućuje definiranje opsega u kojem se tečaj nacionalne valute promijenio u odnosu na tečajeve zemalja trgovanja u odnosu na baznu godinu. Ipak, promjena NEER-a ne sadržava promjene u kupovnoj moći valute te ne sadrži promjenu konkurentnosti dobara u zemlji pokazujući izvozni potencijal tijekom određenog vremenskog razdoblja. Stoga, kako bi se odredio stupanj promjene kupovne moći valute tijekom određenog vremenskog razdoblja, izračunava se REER.

REER je također definiran kao prosjek bilateralnih tečajnih razlika (RER) između zemlje i svakog njenog trgovačkog partnera, pri tome su tečajevi ponderirani odgovarajućim trgovinskim udjelima svakog partnera. Kako je riječ o prosjeku, može se reći da je REER neke zemlje u ravnoteži ako se pronađe precijenjeno u odnosu na jednog ili više trgovinskih partnera, a ujedno je podcijenjen prema ostalim. Realne devizne tečajne liste koriste se za niz svrha kao što su procijenjena ravnoteža vrijednosti valute, promjene cijena ili troškovne konkurentnosti, pokretači trgovinskih tokova ili poticaji za proizvodnju preraspodjele između sektora.

Prednost analize i korištenja REER-a je u tome što je on važna mjera za pojedinu zemlju kod procjene trgovinskih sposobnosti te trenutačne situacije uvoza, odnosno izvoza. Također,

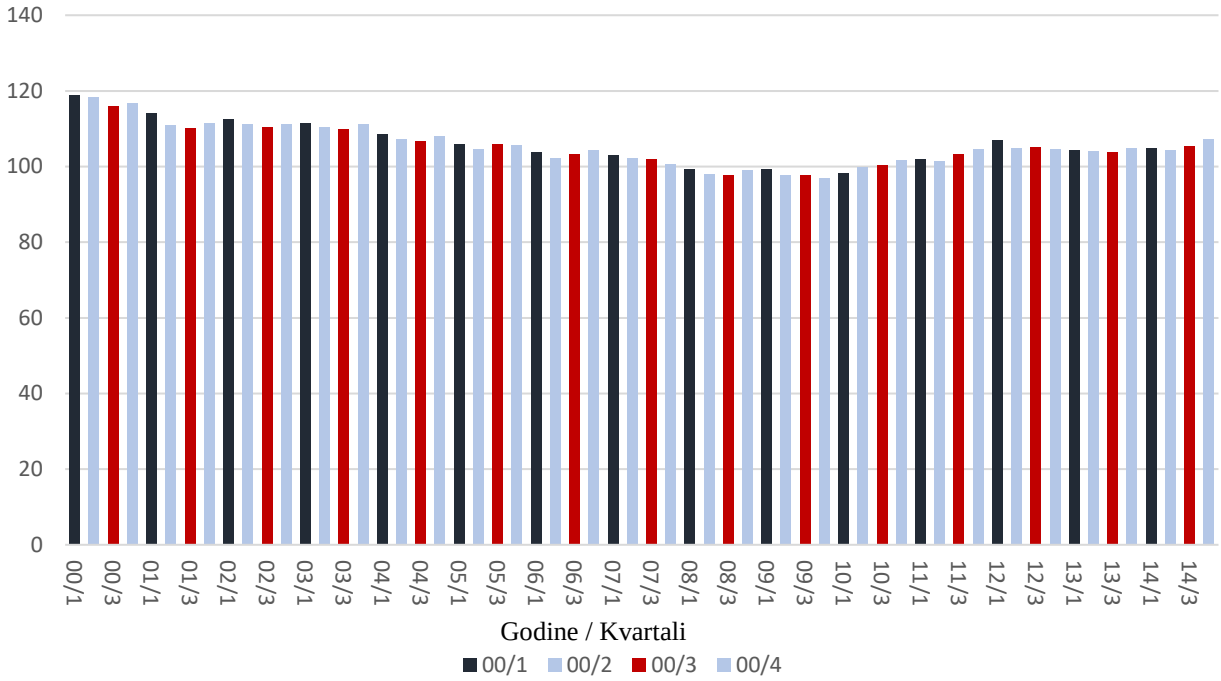
REER se koristi za mjerenje ravnoteže vrijednosti valute, usklađivanje temeljnih čimbenika trgovinskog toka zemlje, promatranje bilo kakvih promjena u međunarodnoj cijeni ili troškovnoj konkurenciji, te kod dodjeljivanja poticaja između sektora koji se mogu razmjenjivati. Zemlja može pozitivno utjecati na svoj REER kroz brz rast produktivnosti. Kada se to dogodi, zemlja ostvaruje niže troškove i smanjuje cijene, čime REER postaje povoljniji za zemlju.

„Promjena indeksa realnog deviznog tečaja odražava promjenu međunarodne konkurentske pozicije zemlje prema inozemstvu. Sniženje realnog deviznog tečaja znači *realnu aprecijaciju* tečaja domaće valute, a povećanje realnog deviznog tečaja znači *realnu deprecijaciju* tečaja domaće valute. Realna deprecijacija domaće valute znači povećanje cjenovne konkurentnosti na međunarodnom tržištu, a realna aprecijacija pogoršanje cjenovne konkurentnosti na međunarodnom tržištu. Na promjenu veličine realnog deviznog tečaja može se djelovati različitim mjerama makroekonomske politike. Do realne deprecijacije tečaja domaće valute može dovesti: porast nominalnog deviznog tečaja, porast cijena u inozemstvu i sniženje cijena u tuzemstvu. Suprotno, do realne aprecijacije tečaja domaće valute može dovesti sniženje nominalnog deviznog tečaja, sniženje cijena u inozemstvu i porast cijena u tuzemstvu. Ovisno o odnosu nominalnog deviznog tečaja (tečaja konverzije) i realnog deviznog tečaja, tečaj valute može biti podcijenjen ili precijenjen. Ako je nominalni devizni tečaj ispod razine koja se smatra realnom, tada je domaća valuta precijenjena, a strana valuta podcijenjena.“ (Marić, 2012).

Da bi se mogao odrediti efektivni devizni tečaj potrebno je odrediti pondere. U praksi se najčešće upotrebljavaju dvije vrste pondera: ponderi na temelju udjela zemalja u bilateralnoj vanjskotrgovinskoj razmjeni i ponderi na temelju multilateralne vanjskotrgovinske razmjene. Zbog značaja REER-a u ekonomskim analizama i istraživanjima politika, više institucija (poput Svjetske banke, EUROSTAT-a, Banke za međunarodna poravnanja, OECD-a i dr.), besplatno objavljuje različite REER pokazatelje. Sve institucije zajedno ukupno objavljuju podatke za 113 zemalja. Stoga, zbog velikog broja zemalja riječ je o različitim bazama podataka koje imaju različitu metodologiju prikupljanja podataka pa kod interpretacije podataka treba biti oprezan. U Republici Hrvatskoj Hrvatska narodna banka (HNB) svakog radnog dana na temelju ugovorenog prometa i tečajeva stranih valuta na tržištu stranih sredstava plaćanja, utvrđuje vrijednost kune prema drugim valutama. Ujedno, održava stabilnost tečaja kune prema euru kako bi mogla ostvariti temeljni cilj, stabilnost cijena.

Hrvatska provodi režim upravljanog fluktuirajućeg tečaja što znači da tečaj nacionalne valute nije fiksiran prema nekoj stranoj valuti nego se slobodno formira na deviznom tržištu. Hrvatska narodna banka povremenim uključivanjem na devizno tržište kontrolira tečajne oscilacije te nastoji održati tečaj relativno stabilnim (Hrvatska narodna banka,2018).

Grafikon 4. Indeks realnog efektivnog deviznog tečaja u Republici Hrvatskoj za razdoblje od 2000./Q1 do 2014./Q4



Izvor: Samostalan rad autorice prema podacima sa službene stranice Hrvatske narodne banke.

Grafikon 4. prikazuje indeks realnog efektivnog deviznog tečaja (REER) u Republici Hrvatskoj u razdoblju od 2000./Q1 do 2014./Q4. Indeksi REER-a se nalaze u prilogu 1. Prema metodologiji prikupljanja podataka HNB-a o REER-u, REER je deflacioniran s indeksom potrošačkih cijena, a bazna godina je 2010=100, i s prosječnim tečajem eura/kune u razdoblju. Također, prema metodologiji u ovom slučaju, pad indeksa označava realnu aprecijaciju hrvatske kune, a rast indeksa realnu deprecijaciju hrvatske kune. U promatranom razdoblju indeks REER-a je zabilježio realnu aprecijaciju hrvatske kune. Od 2000. pa do 2008. godine indeks REER-a bilježi pad, odnosno hrvatska kuna je aprecirala. Aprecijacija kune je izraženija u godinama kada je u Hrvatskoj nastupila svjetska ekonomska kriza. Nakon 2009. godine indeks REER-a bilježi povećanje, odnosno prisutna je realna deprecijacija hrvatske kune. Ukoliko promatranom koji su to uzroci jačanja kune, onda tu prvenstveno možemo izdvojiti povoljno međunarodno okruženje.

3. EMPIRIJSKA POZADINA

Postoji mnogo znanstvenih radova, članaka i studija koji su vezani uz analizu makroekonomskih varijabli i njihovog utjecaja na bruto domaći proizvod. U nastavku će se posvetiti posebna pažnja na prethodna empirijska istraživanja koja se odnose na utjecaj osobne potrošnje, plaća te realnog efektivnog deviznog tečaja na bruto domaći proizvod. Poradi podobnije analize izabranih makroekonomskih varijabli u nastavku će se analizirati i prethodna istraživanja za pojedine zemlje svijeta, dok će se posebna pažnja posvetiti na utjecaj izabranih makroekonomskih varijabli na BDP Republike Hrvatske.

3.1. DOKAZI IZ SVIJETA

Postoji bezbroj radova koji se temelje na istraživanjima kojima je u fokusu analiza makroekonomskih varijabli, nekolicina njih se odnosi na analizu njihovog utjecaja na realni BDP. Individualna želja autora je jedina nit vodilja u kojem smjeru će njegovo istraživanje ići. Ovaj rad se temelji na proizvoljnim odabirom makroekonomskih varijabli, sukladno tome, u daljnjem dijelu teksta dani su značajniji radovi koji se temelje na istraživanju utjecaja osobne potrošnje, plaća i realnog efektivnog deviznog tečaja na bruto domaći proizvod u razvijenim i nerazvijenim zemljama svijeta.

Osobna potrošnja predstavlja ključnu komponentu agregatne potražnje, ali je i najvažnija sastavnica bruto domaćeg proizvoda. Kao takva ima značajan učinak na mnoge pokazatelje kao što su zapošljavanje, investicije i štednja. Upravo iz tog razloga osobna potrošnja je u središtu mnogih analiza. Znatan broj radova je na temu osobne potrošnje, pa tako i Jurić (2017) u svom radu prikazuje osobine osobne potrošnje te njen udio u BDP-u Bosne i Hercegovine. Ujedno, rad daje uvid u promjene vrijednosti potrošnje, te njen utjecaj na BPD u razdoblju od 2007. do 2015. godine. Prema podacima koji su prikazani u radu, vidljivo je da je Bosna i Hercegovina zemlja s niskom ekonomskom snagom po razini razvoja. Potrošnja se gotovo uvijek karakterizira kao pokretač razvoja gospodarstva, pod uvjetom da se industrijska proizvodnja, zapošljavanje i plaće povećavaju što bi utjecalo na povećanje BPP-a za 5% godišnje (Jurić, 2017). Prema ovoj činjenici, pokazatelji Bosne i Hercegovine su daleko od uvjeta. Loša potrošnja i potražnja u Bosni i Hercegovini i dalje ograničavaju ekonomske aktivnosti i predstavljaju rizik za makroekonomsko okruženje ove zemlje. Iako osobna potrošnja čini velik udio u BDP-u Bosne i Hercegovine, 80%, to i dalje nije dovoljno za

razvoj ovog malog otvorenog gospodarstva. U vrijeme krize osobna potrošnja u Bosni i Hercegovini se povećala na kraju 2008. godine. Osobna potrošnja po glavi stanovnika se povećala zbog rasta plaća te je njen udio u BDP-u iznosio 82,83%. No godinu poslije, ovi pokazatelji se mijenjaju, smanjuje se zaposlenost te se usporava i rast gospodarstva. U razdobljima nakon 2009. godine osobna potrošnja u Bosni i Hercegovini stagnira.

Da povećanje BDP-a nema značajniji utjecaj na osobnu potrošnju u svom radu pokazuje Chioma (2009) koristeći regresijsku analizu istražuje donos između BDP-a i osobne potrošnje u Nigeriji. Analizom je dobivena beznačajna vrijednost od 0,0514 kao koeficijenta nagiba koji ukazuje da porast BDP-a nema značajan utjecaj na izdatke u osobnoj potrošnji Nigerije. Navedeno istraživanje temelji se na podacima od 1994. do 2007. godine. Rezultati ove analize pokazali su da je povećanje BDP-a neće nužno dovesti do povećanja osobne potrošnje. Ujedno, Chioma (2009) sugerira da Vlada Nigerije treba povećati ulaganja u zalihe, državnu i lokalnu potrošnju, smanjiti nezaposlenost, povećati izvoz te smanjiti uvoz što bi utjecalo na gospodarski rast i povećanje životnog standarda.

Kako je prijašnjim navedenim istraživanjima spomenuto, najveći utjecaj na produktivnost rada ima životni standard radnika koji se očituje kroz plaće (realne) koju radnici prime za obavljeni rad što posljedično uzrokuje rast osobne potrošnje, ali i potiče gospodarski rast. Stoga u radu Sharpe, Arsenault i Harrison (2008) su proveli istraživanje o odnosu produktivnosti rada i realnih plaća u razdoblju od 1980. do 2005. godine u Kanadi, Sjedinjenim Američkim Državama te ostalim zemljama s visokim prihodima. U navedenom razdoblju realne plaće radnika u Kanadi su stagnirale, a produktivnost rada je pala za 37%. Stoga Izvješće analizira razloge spomenute situacije te identificira četiri čimbenika koji su od jednake važnosti, a to su: povećanje nejednakosti u zaradama, smanjenje udjela radnika u BDP-u, pogoršanje uvjeta rada i način mjerenja. Izvješće istražuje odnos produktivnosti rada i realnih plaća u Kanadi, njenim pokrajinama, te Sjedinjenim Američkim državama i ostalim državama s visokim prihodima. Ključni rezultati iz provedene analize su sljedeći: U Kanadi, tijekom razdoblja od 1961. do 2007. godine, rast obje plaće proizvoda (1,56% godišnje) i (1,67%), općenito je nešto slabiji od rasta produktivnosti rada (1,73%). Udio radne snage tako je između 1961. i 2007. smanjio 0,17 posto godišnje, s 57,5 posto BDP-a na 53,1 posto. Pad udjela radne snage bio je gotovo u cijelosti posljedica kretanja između 1992. i 1997. godine, kada je udio radnika pao sa 57,7 na 54,0 posto, u prosjeku 1,32 posto godišnje. Tijekom tog petogodišnjeg razdoblja, produktivnost rada povećala se 1,26 posto godišnje dok se plaće

proizvoda smanjile za 0,11 posto godišnje. Dok, općenito govoreći, trend među zemljama OECD-a bio je za rast produktivnosti rada i plaća proizvoda pri gotovo istoj stopi. Od 1970. do 2006. godine neusklađeni prosjek 20 zemalja OECD-a ispitanih u ovom izvješću pokazuje da je produktivnost rada porasla s prosječnom godišnjom stopom od 2,33 posto, a plaće za proizvod rastu za 2,28 posto godišnje. Rezultat prosječnog smanjenja udjela radnika u BDP-u bio je sa 51,2 na 50,2 posto. Temeljem navedenog istraživanja možemo zaključiti kako plaće dugoročno mogu utjecati na rast BDP-a jer povećanjem plaća, povećava se životni standard radnika, a samim time se povećava i produktivnost rada koja omogućuje veću proizvodnju, posljedično tome može doći do porasta potrošnje te izvoza.

Mnogi autori promatraju odnos deviznog tečaja i bruto domaćeg proizvoda u razvijenim zemljama svijeta. Što se tiče novijih istraživanja, Habib et al. (2016) istražuju utjecaj kretanja realnog tečaja na gospodarski rast na temelju petogodišnjih prosječnih panel podataka za oko 150 zemlja. Došli su do zaključka da realna aprecijacija (deprecijacija) značajno smanjuje (povećava) rast godišnjeg realnog BDP-a. Navedeni zaključak se može primijeniti samo na zemlje u razvoju. Rezultati koji su dani ovim radom upućuju na vladino promišljeno upravljanje tečajem kako bi se ostvario kontinuirani rast BDP-a. Kratkoročno tečajna politika u ranijim fazama gospodarskog rasta može biti korisna, ali dugoročno postaje irelevantna.

Nadalje, Stavarek (2013) iznosi empirijske veze između nominalnog i realnog efektivnog tečaja, realnog BDP-a, potrošnje, investicija, izvoza, uvoza te općeg vladinog duga za grupu od deset zemalja središnje i istočne Europe. U radu se koristila „poprečnu korelaciju na ciklički filtriranim i sezonski prilagođenim kvartalnim vremenskim serijama u periodu od 1998. Do 2010.“ Dobiveni rezultati se razlikuju po intenzitetu, ali pokazuju slabu vezu između tečajnih stopa i fundamenata. Korelacija između tečajnih stopa i makroekonomskih agregata teži ka jačoj izraženosti u manje otvorenim te relativno siromašnijim zemljama. Cilj rada je pružiti izravanu empirijsku potvrdu o odnosu između tečaja i odabranih makroekonomskih varijabli za skupinu deset Europske unije (EU) nove države članice Srednje i Istočne Europe (Bugarska, Češka, Estonija, Latvija, Litva, Mađarska, Poljska, Rumunjska, Slovačka, Slovenija). Kako bi se povećala pouzdanost rezultati empirijske procjene se provode s obzirom na poslovne cikluse i ciklička svojstva korištene makroekonomske varijable. Rezultati provedene analize, generalizirano, potvrđuju da tečaj ima najjači učinak na državi dug, dok u manjoj mjeri utječe na uvoz. Odnos između tečaja i

BDP-a je očitiji ako se REER koristi u analizi korelacije. Učinkovit tečaj dovodi do rasta BDP-a uglavnom za četiri četvrtine.

Marić (2012) u svom radu analizira „utjecaj politike deviznog tečaja na promjenu strukture bosanskohercegovačkog gospodarstva od uvozno ovisne u izvozno orijentiranu privredu“. Bosna i Hercegovina vodi sustavnu politiku precijenjenosti tečaja nacionalne valute jer je realni tečaj nacionalne valute niži od nominalnog. Ovaj način politike negativno utječe na saldo vanjske trgovine i sve veću inozemnu zaduženost. Autor navodi kako bi se realnom deprecijacijom tečaja KM, smanjila „precijenjenost nominalnog tečaja KM i omogućila objektivna informiranost tržišnih subjekata o relativnim cijenama domaćih i inozemnih dobara, što je neophodno za efikasno restrukturiranje gospodarstva BiH i uključivanje na međunarodno tržište.“

3.2. EMPIRIJSKI TEMELJ ZA REPUBLIKU HRVATSKU

Mnoštvo radova analizira utjecaj osobne potrošnje, plaća i realnog efektivnog tečaja, no nekolicina njih analizira utjecaji istih varijabli na BDP Republike Hrvatske, u ovom radu će se istaknuti neki od značajnijih radova, al i publikacija. Kretanje BDP-a u Hrvatskoj najbolje možemo vidjeti u analizi koja je objavljena u publikaciji, Hrvatske gospodarske komore (koja je jedna od značajnijih institucija u Republici Hrvatskoj koja prati kretanja makroekonomskih varijabli), „Kretanje BDP-a u Hrvatskoj – napokon osjetniji rast“ (2017) u kojoj se navodi kako dugoročna analiza kretanja BDP-a u razdoblju nakon Domovinskog rata pokazuje da je ostvaren stabilan i djelomičan gospodarski rast. Uzrok gospodarskog rasta, u razdoblju nakon Domovinskog rata, je stabilna baza, prvenstveno ukupnog BDP-a, ali i pojedinih komponenti poput osobne potrošnje, plaća, kreditnih plasmana, investicija ili izvoza roba i usluga te snažnom kreditnom aktivnošću i vanjskim zaduživanjem. Vrlo važna činjenica je da je rast BDP-a ostvaren u uvjetima kreditnog zaduživanja stanovništva i ostalih sektora, smanjivanjem vanjskog duga, ali i stagniranja duga opće države. Rast BDP-a i dalje je na niskoj razini gospodarske aktivnosti.

Čitajući prijašnja istraživanja, analize o osobnoj potrošnji kao jednoj od glavnih komponenti bruto domaćeg proizvoda, nailazimo na mnoštvo radova koji se bave upravom navedenim i dolaze do relativno sličnih zaključaka. Tako, Denona Bogović (2002) istražuje dugoročna obilježja osobne potrošnje u Republici Hrvatskoj, a dobiveni rezultati istraživanja

komparirani su sa kretanjem osobne potrošnje u odabranim zemljama u kojima je tržišni sustav razvijen, te u tranzicijskim zemljama. Istraživanje obilježja osobne potrošnje u Republici Hrvatskoj provedeno je za razdoblje od 1966. godine do 1999. godine, radi potrebe istraživanja provedena je metodološka prilagodba praćenja osobne potrošnje prema metodologiji Svjetske banke i Eurostata. Zaključak istraživanja navodi kako je dugoročno, osobna potrošnja u Republici Hrvatskoj ispod prosjeka zemalja koje su po stupnju razvijenosti u istoj skupini kao Republika Hrvatska. Također, rezultat istraživanja daje zaključak kako osobna potrošnja dugoročno ima negativne makroekonomske efekte, posebice na strukturne promjene proizvodnje i gospodarstva, zaposlenosti, životni standard stanovništva.

Da bi se osigurao veći životni standard te osobna potrošnja dugoročno imala pozitivne makroekonomske posljedice, potrebno je utjecati na osnovni dohodak pojedinca, plaće, što potvrđuju provedene analize. Plaće su jedna od najintrigantnijih tema u ekonomsko-socijalnim analizama zbog svoje dvostruke uloge. S jedne strane su dohodak radnika koji je ostvaren kao naknada za obavljeni rad. Za radnika i njegovu obitelj plaće su najčešće dominantan izvor sredstava za život, koji radniku donosi osjećaj korisnosti ili vrijednost. Dok, s druge strane, plaće su trošak poslovanja za poslodavca. Takvo dvojstvo plaća dovodi do različitih stavova. U radu „Plaće u Hrvatskoj: Trendovi, problemi i očekivanja“, Nestić (2009) ponajprije daj pregled osnovnih trendova kretanja plaća u Hrvatskoj. U radu je promatrano kretanje plaća kroz prizmu statističkih podataka, s naglaskom na osnovne neravnoteže/probleme te očekivanja u vremenu gospodarske recesije 2009. godine. Ujedno, rad se sastoji od komparacije plaća u Hrvatskoj sa plaćama drugih zemalja Srednje i Istočne Europe. Iz analize koja je provedena uočeno je da trendovi u Hrvatskoj odgovaraju globalnim kretanjima, koje karakterizira solidan rast realne plaće uz smanjenje udjela plaća u BDP-u te povećanje razlika u plaćama. Nadalje, Radman Peša et al. (2011) istražuju ekonomski položaj Hrvatske u odnosu na EU 27 zemlje i druge tranzicijske zemlje regije (Bosna i Hercegovina, Srbija i Crna Gora) s obzirom na plaće, razinu potrošačkih cijena i potrošačku košaricu u RH. Istraživanje je provedeno u razdoblju od 2001. godine do 2010. godine, a temelji se na dostupnim statističkim podacima te vlastitim izračunima autora koji su temeljeni na metodi komparacije. Promatrajući položaj Hrvatske u odnosu na zemlje u regiji, primjerice Bosnom i Hercegovinom, Srbijom i Crnom Gorom, vidljivo je da Hrvatska ima znatno bolji ekonomski položaj. Povoljniji ekonomski položaj Hrvatske u odnosu na zemlje u regiji nije zadovoljavajući ukoliko se radi komparacija sa zemljama Europske Unije. Navedeno istraživanje je pokazalo da je situacija u Hrvatskoj sve gora što se tiče plaća i troškova života.

Troškovi života su svaki dan sve veći, a plaće zbog dodanih većih poreznih opterećenja sve manje. Također, u radu se navodi da zbog posljedica bržeg rasta BDP-a udio plaća u BDP-u Hrvatske se znatno smanjuje.

Jedan od temeljnih ciljeva Hrvatske narodne banke je stabilnost tečaja. Mnoštvo radova se bazira upravo na politici tečaja te njenoj transparentnoj provedbi. Upravo, u svom radu Zdunić (2003) analizira „desetogodišnje kretanje indeksa realnih efektivnih tečajeva i relativnih cijena skupine tranzicijskih zemalja – kao iskaza alternativnih polazišta monetarnih i ekonomskih politika; posebno se analiziraju pitanja konvergencije prema zajedničkoj valuti, odnosno prema EU.“ U radu se propituje koliko je slaboj razvojnoj djelotvornosti hrvatskog gospodarstva pridonijela politika tečaja i stabilnosti cijena. Spomenuta politika nije povezana s kriterijem pune zaposlenosti potencijalnog gospodarstva, te nije povezana s uravnoteženjem platne bilance. Polazište rada je hrvatska tečajna politika koja se komparira s konkurentskim zemljama. Odnosno, analizirano je kretanje realnih efektivnih tečajeva Češke Republike, Mađarske, Slovenije i Hrvatske. Ono što je proizašlo iz ove analize je sljedeće: u pitanje je dovedena ideologija čvrstog tečaja kao instrumenta proizvodnosti i restrukturiranja; „međuodnos strukturnih politika i monetarno-tečajne politike nije postavljen po kriteriju razvitka; izostala je fazna razvojna strategija, čime je redoslijed ekonomskih politika pomiješan: monetarnih, tečajnih i fiskalnih, pa prema tome i politika deregulacije i liberalizacije u realnome sektoru gospodarstva i u bankarstvu.“

Podobniju analizu bruto domaćeg proizvoda navode Broz et al. (2012) u prilogu (dio rada „Aktualna ekonomska kretanja“) osvrnuli su se na BDP Republike Hrvatske u trećem tromjesečju 2012. godine. Ističu da su negativna gospodarska kretanja uzrokovala pad gotovo svih sastavnica agregatne potražnje. Pozitivna kretanja zabilježena su samo kod neto izvoza. U promatranom razdoblju osobna potrošnja je zabilježila smanjenje u odnosu na isto razdoblje 2011. godine. Negativno kretanje osobne potrošnje uzrokovani su negativnim trendovima na tržištu rada, rastom troškova života te slabljenjem potrošačkog optimizma stanovništva. Također, negativno kretanje bilježi i državna potrošnja, investicije kao i realni izvoz roba i usluga. U radu, Broz et al. (2012), ističu smanjenje industrijske proizvodnje u četvrtom tromjesečju 2012. godine, pad maloprodaje tijekom jeseni, kao i negativna kretanja u gospodarstvu. Nasuprot ukupnim gospodarskim kretanjima, turistički sektor u promatranom razdoblju bilježi rast aktivnosti. Vanjskotrgovinska razmjena u promatranom razdoblju se oporavlja, ali se nastavlja zaduživanje države u inozemstvu. Povećava se nezaposlenost i

smanjuju se plaće. Najveće smanjenje plaća zabilježeno je u pomoćnim djelatnostima kod financijskih usluga i djelatnostima osiguranja, u upravljačkim te savjetodavnim djelatnostima, kao i u djelatnosti socijalne skrbi bez smještaja. Istovremeno, najveća povećanja realnih neto plaća zabilježeno je u ostalim stručnim, znanstvenim i tehničkim djelatnostima. Također, u radu su se osvrnuli na tečaj kune koji je stabilan na kraju godine. U 2012. godini oscilacije tečaja ostvarene su bez značajno izraženog trenda rasta ili pada.

4. EKONOMETRIJSKA ANALIZA VARIJABLI

4.1. POVEZANOST IZMEĐU VARIJABLI

U prethodnim poglavljima ovog rada dan je teorijski okvir varijabli koje će se koristi u izradi ekonometrijskog modela koji će u daljnjem dijelu rada biti prikazan. Stoga, u analizi se koriste sljedeće varijable: realni bruto domaći proizvod, osobna potrošnja, realne bruto plaće te realni efektivni devizni tečaj. Zavisna varijabla modela je realni bruto domaći proizvod dok su ostale varijable (osobna potrošnja, realne bruto plaće i realni efektivni devizni tečaj (REER)) nezavisne. Cilj modela je prikazati utjecaj izabranih nezavisnih varijabli na zavisnu varijablu. Odnosno, cilj je prikazati utjecaj osobne potrošnje, realnih bruto plaća i realnog efektivnog deviznog tečaja na realni BDP Republike Hrvatske. Također, bit će prikazan međusoban odnos varijabli modela što će u daljnjem dijelu rada biti i grafički prikazano.

Kada promatramo vezu realnog bruto domaćeg proizvoda i osobne potrošnje, podaci pokazuju da je među njima jaka dugoročna ekonomska veza. Osobna potrošnja je komponenta BDP-a koja u prosjeku čini 2/3 bruto domaćeg proizvoda stoga njena kretanja znatno utječu na cjelokupno gospodarstvo. U vremenskom razdoblju od 2000. do 2014. godine prosječan udio osobne potrošnje u BDP-u Republike Hrvatske kretao se oko 60% (DZS, 2018).

Nadalje, između BDP-a i realnih bruto plaća postoji dugoročna linearna veza. Prema podacima koji su korišteni u ovoj analizi, realne bruto plaće u promatranom razdoblju negativno utječu na rast BDP-a Hrvatske. Razlog tome su nepovoljni trendovi kretanja na tržištu rada koji su posljedica globalne ekonomske krize koja je zahvatila i Hrvatsku. Upravo spomenuti trendovi negativno doprinose realnom rastu realnih bruto plaća na godišnjoj razni. Da bi se postigla pozitivna veza realnih bruto plaća i BDP-a potrebne su porezne reforme, kada bi se postigao godišnji rast plaća u Hrvatskoj to bi se pozitivno odrazilo i na visinu raspoloživog dohotka, čime bi se posredno utjecalo i na povećanje osobne potrošnje kao najznačajnije komponente BDP-a, tj. utjecalo bi se na ukupan gospodarski rast.

Temeljem podataka koji se odnose na posljednji promatrani odnos, odnos BDP-a i deviznog tečaja, ukazuju na činjenicu da ovaj odnos svojim svojstvima ukazuje na jaku dugoročnu ekonomsku vezu. Levy – Yeati i Sturzenrgger (2007) istraživanjem koje su proveli, došli su do zaključka da će deset postotna deprecijacija utjecati na rat stope BDP-a za 0,14% iduće

godine. Deprecijacijom domaće valute, u ovom slučaju kune, utjecalo bi se na povećanje izvoza, a smanjenje uvoza, što bi posljedično uzrokovao rast BDP-, ali i plaća, samim time i osobne potrošnje, odnosno, povećao bi se životni standard, ali i gospodarski rast.

4.2. OBILJEŽJA NEZAVISNIH VARIJABLI

4.2.1. Osobna potrošnja

Pod pojmom „izdaci za potrošnju“ kućanstva podrazumijevamo novčanu te nenovčanu potrošnju proizvoda, ali i usluga kojima je svrha zadovoljenje životnih potreba članova kućanstva. Prema međunarodnoj klasifikaciji COICOP (Classification of Individual Consumption by Purpose) struktura izdataka za potrošnju prati se kroz dvanaest glavnih odjeljaka, a to tu: hrana i bezalkoholna pića, alkoholna pića i duhan, odjeća i obuća, pokućstvo, stanovanje i potrošnja energenata, oprema za kuću i redovito održavanje kuće, zdravstvo, prijevoz, komunikacije, rekreacija i kultura, obrazovanje, restorani i hoteli te ostala dobra i usluge.

Državni zavod za statistiku prikuplja podatke o potrošnji kućanstva putem ankete koja se provodi na uzorku privatnih kućanstava. Anketa se provodi u skladu s metodološkim međunarodnim standardima te preporukama Eurostata. Kao što je prethodno navedeno, struktura izdataka za potrošnju kućanstva prati se temeljem međunarodne klasifikacije COICOP. Prema metodologiji, anketom su obuhvaćena privatna kućanstva, dok institucionalno stanovništvo i potrošnja stranih turista ne ulaze u obuhvat istraživanja. Pod institucionalnim stanovništvom smatramo zatvore, domove i bolnice za trajni smješta osoba i slično (Statistički ljetopis, 2013).

4.2.2. Plaće

„Mjesečna isplaćena neto plaća obuhvaća plaće zaposlenih u pravnim osobama za izvršene poslove prema osnovi radnog odnosa i naknade za godišnji odmor, plaćeni dopust, blagdane i neradne dane određene zakonom, bolovanja do 42 dana, odsutnost zbog stručnog obrazovanja, zaostajanje na poslu bez krivnje zaposlenoga, naknadu za topli obrok i primitke prema osnovi naknada, potpora i nagrada u iznosima na koje se plaćaju doprinosi, porezi i prirezi. Mjesečna bruto plaća obuhvaća sve vrste neto isplata prema osnovi radnog odnosa i

zakonom propisana obvezatna izdvajanja, doprinose, poreze i prireze. Podaci o prosječnim mjesečnim isplaćenim neto i bruto plaćama prate se redovitim mjesečnim istraživanjem kojim je obuhvaćeno 70% zaposlenih u svakom odjeljku Nacionalne klasifikacije djelatnosti 2007. Istraživanjem se prikupljaju podaci od pravnih osoba svih oblika vlasništva, tijela državne vlasti te tijela jedinica lokalne i područne (regionalne) samouprave na području Republike Hrvatske. Podaci o prosječnoj mjesečnoj isplaćenoj neto plaći prema stupnjevima stručne spreme i podaci o strukturi zaposlenih prema visini isplaćene neto plaće prate se godišnjim istraživanjem kojim se obuhvaćaju pravne osobe svih oblika vlasništva, tijela državne vlasti te tijela jedinica lokalne i područne (regionalne) samouprave. Od 2003. godišnjim istraživanjem prate se podaci o prosječnoj mjesečnoj bruto plaći prema stupnjevima stručne spreme, a od 2004. podaci o prosječnim plaćama prate se i prema spolu.“ (Statistički ljetopis, 2013).

Državni zavod za statistiku podate o plaćama u pravim osobama prikuplja na temelju evidencije o plaćama koja obuhvaća neto i bruto plaće zaposlenih bez obzira na vrstu radnog odnosa te duljini radnog vremena. Od 1994. godine osim mjesečnih podataka o prosječnim isplaćenim neto plaćama prate se i podaci o prosječnim bruto plaćama. Od 2003. godine DZS na temelju mjesečnog istraživanja prati i podatke o broju sati za koje su zaposleni primili plaću.

U mjesečna i godišnja istraživanja o prosječnim neto i bruto plaćama ne ulaze isplate zaposlenih u djelatnostima obrta te slobodnih profesija, policije i obrane, ali ni zarade osoba koji svoju aktivnost obavljaju na individualnim poljoprivrednim gospodarstvima. Od 2004. godine u podatke o prosječnim plaćama ulaze i isplate zaposlenih u obrani i policiji.

4.2.3. Realni efektivni devizni tečaj

Temeljem ugovorenog prometa te tečajeva stranih valuta koje se pojavljuju na tržištu stranih sredstava plaćana, središnja banka Republike Hrvatske, Hrvatska narodna banka (HNB) svakog radnog dana utvrđuje vrijednost nacionalne valute, kune, prema drugim valutama. Središnja banka Republike Hrvatske, HNB, održava stabilnost tečaja kune prema euru radi ostvarenja svog temeljnog cilja koji se odnosi na stabilnost cijena. Promjene tečaja usko su povezana i s inflacijskim očekivanjima stanovništva. Na ovim prostorima u prošlosti su iznimno naglašena negativna iskustva s visokom inflacijom. Hrvatska trenutno provodi režim upravljanog fluktuirajućeg tečaja što znači da tečaj nacionalne valute nije fiksiran prema

drugoj stranoj valuti već se slobodno formira na deviznom tržištu. Vrijednost nacionalne valute (kune) prema drugim valutama objavljuje se na tečajnoj listi Hrvatske narodne banke, a temeljna valuta za izradu tečajnice HNB-a je euro. Kretanja na deviznom tržištu uvelike ovise o novčanim tokovima s inozemstvom, npr. plaćanje uvoza te naplata izvoza, priljevi na osnovi fondova Europske Unije i sl.. Tečaj nacionalne valute, kune, slobodno se formira na deviznom tržištu pri tome da velik utjecaj ima kretanje ponude deviza i potražnja za devizama. Hrvatska narodna banka povremeno intervenira na deviznom tržištu, najčešće je to slučaj kada ocijeni da je prisutno kolebanje tečaja. Hrvatska narodna banka ne utvrđuje gornju i donju granicu kretanja tečaja kune prema euru koju se obvezuje braniti (Hrvatska narodna banka, 2018).

4.3. PODACI

Varijable koje se koriste u analizi transparente su za prikaz dijela makroekonomske situacije u Republici Hrvatskoj. Analiza modela temeljena je na vremenskom periodu od 2000. do 2014. godine. Vremenskim periodom od četrnaest godina obuhvaćena je ekonomska kriza koja je u Hrvatskoj nastupila 2008. godine, što će nam omogućiti da vidimo kako je spomenuta kriza utjecala na promatrane varijable. Ujedno, analiza je temeljena na kvartalnim podacima za prethodno navedeno razdoblje (2000Q1 do 2014Q4) koji su dostupni na službenim stranicama Državnog zavoda za statistiku (DZS) te na stranici Hrvatske narodne banke (HNB).

Kvartalni podaci koji su korišteni u analizi, prije same analize i izrade modele, su desezonirani te logaritmirani. Desezonacija kvartalnih podataka izrađena je pomoću ARIMA X-12 modela. Ovaj model se koristio jer postupak predviđa postojanje prošlih pogrešaka (šokova), te ujedno pruža skup alata za jednoznačno određivanje modela vremenskog slijeda, procjenu parametara i predviđanje, na taj način omogućava veliku fleksibilnost podataka (Tomić, 2014).

U daljnjem dijelu rada dan je detaljan prikaz varijabli, tj. varijable će biti grafički prikazane, dan je vektorski model ispravljanja pogreški (Vector error correction model - VECM), te impulsne funkcije promatranih varijabli u navedenom razdoblju. U analizi varijable su zbog desezoniranja i logaritmiranja poprimile nazive kako ih je formirao program koji je korišten u analizi, Gretl. Stoga, varijabla BDP poprima oznaku l_bdp_d11, osobna potrošnja je oznake l_c_d11, realne bruto plaće su oznake l_place_d11 i realni efektivni tečaj je označen

l_reer_d11. Zbog metodologije koju prati Hrvatska narodna banka, pad indeksa realnog efektivnog deviznog tečaja označava realnu aprecijaciju hrvatske kune, dok rast indeksa označava realnu deprecijaciju hrvatske kune. Slijednom toga, u ovom radu će se koristiti ovaj način objašnjenje povećanja i smanjenje indeksa realnog efektivnog deviznog tečaja.

Tako desezonirani i logaritmirani podaci će se koristiti u izradi VECM modela na kojemu napravljena analiza povezanosti varijabli. Ponuđen je i test reda integriranosti varijabli koji treba otkriti postojanje jediničnog korijena, ADF (Argumented Dickey Fuller) test. Ujedno, su prikazane impulsne funkcije te testovi heteroskedastičnosti, autokorelacije i normalnosti distribucije. Stoga, u daljnjem dijelu rada, dana su objašnjenja te prikazi svega što je prethodno navedeno.

Da bismo otkrili postojanje jediničnog korijena koristili smo ADF test koji za nul-hipotezu pretpostavlja nestacionarnost varijabli. ADF test testira hipotezu o procesu sa slučajnim hodom s otklonom. Ovaj test, za β=0, proučava proces s jediničnom svojstvenom vrijednošću nasuprot stacionarnom procesu (Tomić, 2012).

Tablica 1. ADF (Argumented Dickey Fuller) test

Varijable	U razinama		U prvoj diferenciji	
	Konstanta	Konstanta + trend	Konstanta	Konstanta + trend
BDP	0,584568	0,533223	-0,000168474	0,0108948**
Osobna potrošnja	0,707090	0,341008	0,00252214	0,0163499**
Realne bruto plaće	0,578829	0,0786189	0,00211872	0,0087656***
REER	0,225322	-0,100961	8,36098e-05	-0,0141066***

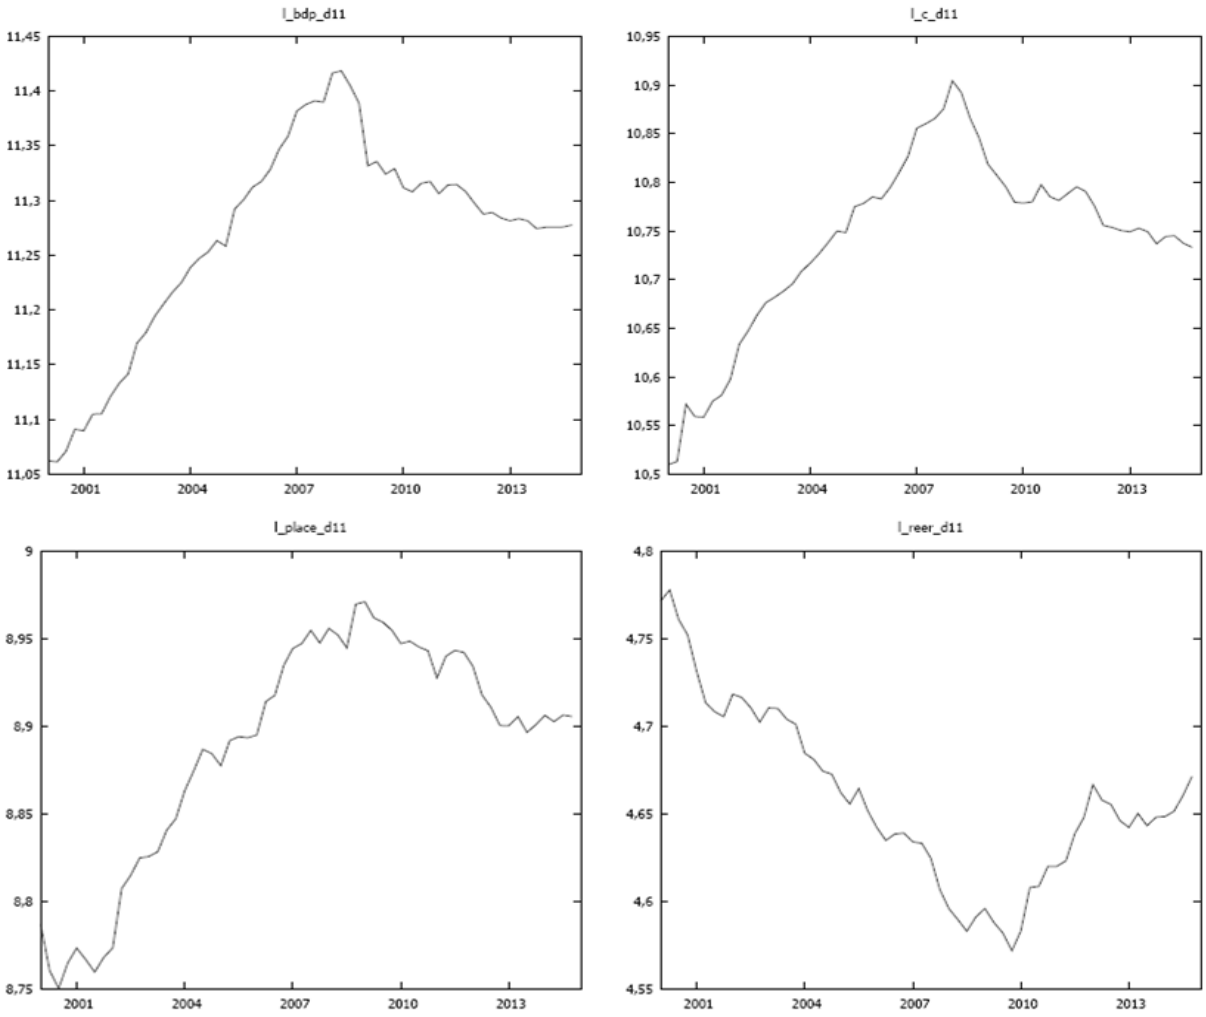
***, **, * predstavljaju 1%, 5% i 10% razinu značajnosti

Izvor: Izračun autorice (Gretl 2017d).

U tablici 1. je prikazan ADF test za varijable (realni BDP, osobnu potrošnju, plaće te za REER) u razinama te u prvoj diferenciji. Za konstantu i konstantnu s trendom možemo uočiti postojanje jediničnog korijena, odnosno da varijable u razini nisu stacionarne. Nestacionarnost varijabli vidljiva je na grafikonu 1.. Stoga idemo analizirati iste u prvoj

diferenciji. Kada promatramo varijable u prvoj diferenciji uviđamo kako iste postaju stacionarne u prvoj diferenciji uz konstantu s trendom, odnosno kažemo da su istog reda integriranosti I(1), što znači da su sve varijable istog reda integriranosti. Kako imamo varijable istog reda integriranosti moguće je primijeniti metodologiju kointegracije i povezanog VECM pristupa.

Grafikon 5. Prikaz varijabli BDP-a (l_bdp_d11), osobne potrošnje (l_c_d11), realnih bruto plaća (l_place_d11) i realnog efektivnog tečaja (l_reer_d11) za razdoblje od 2000Q1 – 2014Q4



Izvor: Izrada autorice (Gretl 2017d).

Grafikon 5. prikazuje kvartalne podatke za razdoblje od 2000. godine prvog kvartala do 2014. godine četvrtog kvartala. Na grafikonu su prikazane varijable (BDP, osobna potrošnja, plaće i realni efektivni tečaj) i njihovo kretanje u promatranom razdoblju. Grafikon prikazuje kretanje BDP-a, vidljivo je da u promatranom razdoblju BDP bilježi povećanje. Vidljivo je

znatno povećanje BDP-a u razdoblju od 2000. godine do 2008. godine, nakon 2008. godine BDP bilježi smanjenje zbog utjecaja krize koja je zahvatila hrvatsko gospodarstvo. Nakon 2009. godine pa sve do 2014. godine četvrtog kvartala BDP poprima ne toliko značajne trendove povećanja i smanjenja. Grafikon osobne potrošnje prikazuje njeno značajnije povećanje u razdoblju od 2000. godine do 2008. godine. Nakon 2008. godine osobna potrošnja bilježi značajnije smanjenje zbog utjecaja krize. Nakon 2009. godine plaće bilježe povećanje i nešto blaže smanjenje na kraju promatranog razdoblja. Također, grafikon prikazuje kretanje realnih bruto plaća u promatranom razdoblju. Vidljivo je da plaće u promatranom razdoblju bilježe povećanje. Značajnije povećanje realnih bruto plaća je u razdoblju od 2000. godine do 2008. godine, no nakon te godine realne bruto plaće bilježe značajno smanjenje zbog prisutne krize u gospodarstvu te do kraja promatranog razdoblja plaće ne poprimaju značajan trend povećanja. Posljednji dio grafikona se odnosni na promatranje kretanja realnog efektivnog tečaja u promatranom razdoblju. Realni efektivni tečaj u promatranom razdoblju oscilira. U razdoblju od 2000. godine do godine u kojoj je nastupila kriza tečaj je aprecirao, nakon 2009. godine tečaj deprecira.

4.4. Odabir lagova i kointegracijskog ranga

Kako bi analizirali povezanost varijabli prvo što moramo učiniti, definirati broj lagova koji ćemo dobiti putem vektorske autoregresije (VAR). O redu VAR-a ovisi ponašanje funkcija odgovora na impuls kao i dekompozicija varijance prognostičke greške te se moramo voditi prema određenim pravilima po izboru reda VAR. Prema tome, postoje četiri testa za testiranje reda VAR-a, a poznati su kao FPE (final prediction error correction), AIC (Akaike), HQ (Hannan i Quinn) te SC (Schwarz).

Kako bismo odabrali red VAR-a biramo ga temeljem minimizacije vrijednosti. Odnosno, biramo red VAR-a koji minimizira FPE vrijednosti te ga uzimamo kao ocjenu za p-vrijednosti. Kod AIC kriterija biramo red VAR-a koji minimizira AIC vrijednost. Vodeći se istom logikom, navedeno primjenjujemo i kod HQ i SC kriterija. Ako u ekonometrijskoj analizi imamo mali uzorak, tada će za odabir reda VAR-a relevantniji biti FPE i AIC kriteriji od HQ i SC. U prisustvu nestacionarnih procesa relevantniji će biti HQ i SC kriteriji od AIC i FPE kriterija (Belullo, 2008).

Model za promatrane varijable (BDP, osobnu potrošnju, plaće i REER) odabir lagova je pokazao dva različita odabira laga (vidjeti prilog 2.). Na temelju vrijednosti koje nam pokazuju AIC, BIC i HQC kriteriji zaključujemo da: prema AIC postoje dva laga, dok BIC i HQC pokazuju da postoji jedan lag. U daljnjoj analizi koristit će se kriteriji BIC i HQC, odnosno jedan lag jer zadovoljavaju pretpostavku normalnosti odstupanja te nepostojanja autokorelacije.

Ukoliko postoji kointegracijska veza između varijabli, nije primjereno u analizu uključiti varijable u prvoj diferenciji u reducirani VAR jer time zanemarujemo kointegracijsku vezu, ali i korekciju odstupanja dugoročnoj ravnotežni koja se zbog kointegracije pojavljuje. Stoga radimo kointegracijsku analizu koja se izvodi na temelju Johansenovog pristupa (Belullo, 2008). Da bismo odredili kointegracijski rang koristili smo Johansenov test. Johansenov test nam pokazuje, odnosno određuje broj kointegracijskih vektora matrice π koja se temelji na propoziciji da je rang određene matrice jednak broju svojstvenih vrijednosti matrice različitih od nula (Belullo, 2008).

Johansenov test (vidjeti prilog 3.) nam pokazuje koliko veza postoji između varijabli koje analiziramo te kakva je ta veza u konačnici. Stoga, na temelju p-vrijednosti koja je manja od 0,05 (0,0004) možemo odbaciti hipotezu da nam je rang 0. Što znači da imamo VAR u prvoj diferenciji. No, na temelju p-vrijednosti koja je veća od 0,05 (0,0886) ne možemo odbaciti hipotezu da nam je rang jednak jedan. Iz toga zaključujemo da između varijabli (BPD, osobna potrošnja, plaće, REER) postoji jedna dugoročna kointegracijska veza. Dugoročna kointegracijska veza će se promatrati kroz VECM model; Case 3. zbog automatskog odabira programa koji je korišten u analizi.

4.5. Kointegracija (dugi rok)

VECM metodologija je jedna od najraširenijih ekonometrijskih metodologija koja se koristi za analizu povezanosti, odnosno za kointegraciju vremenskih serija. Ova metodologija obuhvaća grafičku analizu impulsnih funkcija varijabli u modelu kao i niz dijagnostičkih testova postavljenog modela. Kointegriranost varijabli upućuje na postojanje dugoročne linearne veze među varijablama.

Prema Engel i Grangeru (1987) i Johansenu (1991) varijable su kointegrirane jedino ako postoji vektorski prikaz s korekcijom odstupanja vremenskih serija. Jednu od najznačajnijih stavki kointegracijske analize je utvrđivanje ranga dugoročne matrice ∏. Kako je matrica ∏ *n* x *n* reda, maksimalni mogući rang je nula. U tom slučaju matrica ∏ sadrži nul-elemente te kratkoročni elementi ne ovise o elementima vektora Z. Drugi slučaj je kada rang *n* podrazumijeva da su sve endogene varijable vektora Z stacionarne, odnosno I(0). Stoga je statistička hipoteza kointegracije H(p): rang(∏)≤ r, gdje je r rang dugoročne matrice. U ovom slučaju, pod nul-hipotezom matrica ∏ može biti rastavljena na produkt dviju matrica koje ne sadrže nul-elemente, i to ∏=αβ. Matrice α i β sadrže koeficijente korekcije odstupanja varijabli u modelu prema dugoročnoj ravnoteži koja je definirana kointegrcijskim vektorom i sadrži koeficijente dugoročne ravnoteže, veličine *n* x *r*.

VECM system, lag order 1

Maximum likelihood estimates, observations 2000:2-2014:4 (T = 59)
Cointegration rank = 1

Case 3: Unrestricted constant

beta (cointegrating vectors, standard errors in parentheses)

l_bdp_d11	1,0000
	(0,00000)
l_c_d11	-1,6752
	(0,12815)
l_place_d11	1,1508
	(0,22169)
l_reer_d11	0,089192
	(0,22902)

alpha (adjustment vectors)

l_bdp_d11	-0,20337
l_c_d11	-0,098193
l_place_d11	-0,18594
l_reer_d11	0,087645

Log-likelihood = 759,77444

Determinant of covariance matrix = 7,6704297e-017

AIC = -25,0771

BIC = -24,3728

HQC = -24,8022

Izvor: Izračun autorice (Gretl2017d).

$$\mathbf{l_bdp_dl1 = \beta_1\, l_c_d11 + \beta_2\, l_place_d11 + \beta_3\, l_reer_d11}$$

$$\mathbf{l_bdp_dl1 = \underset{(0,01282)}{1,6752\, l_c_d11} \underset{(0,22169)}{-1,1508\, l_place_d11} \underset{(0,22902)}{-\,0,0892\, l_reer_d11}}$$

Kvalitetu modela testirat ćemo testom autokorelacije, testom heteroskedastičnosti te testom normalnosti distribucije. Test autokorelacije reziduala radimo izračunavanjem Ljung-Boxovog Q pokazatelja kojeg su Ljung i Box pokazali u svom članku 1978. godine. Temeljem dobivenih p-vrijednosti zaključujemo postoji li autokorelacija ili ne postoji. Ako su p-vrijednosti veće od 0,05 s 5% značajnosti možemo odbaciti hipotezu da imamo problem s autokorelacijom. Kada su p-vrijednosti manje od 0,05 s 5% značajnosti ne možemo odbaciti hipotezu da imamo problem s autokorelacijom. Postojanje hteroskedastičnosti testirat ćemo pomoću ARCH modela. Ovim testom testiramo mogućnost da su svi koeficijenti regresije jednaki nuli. Kao i kod testa autokorelacije reziduala, tako i kod testa heteroskedastičnosti, dobivene p-vrijednosti interpretiramo na isti način.

Testom autokorelacije (vidjeti prilog 5.) potvrđeno je da kod niti jedne varijable nemamo problem s autokorelacijom jer su sve p vrijednosti u testovima veće od 0,05. Što znači da s 5% značajnosti možemo odbaciti hipotezu da imamo problem s autokorelacijom. Testom heteroskedastičnosti (vidjeti prilog 6.) potvrđeno je da kod niti jedne varijable nemamo problem s heteroskedastičnosti jer su sve p vrijednosti u testovima veće od 0,05. Što znači da s 5% značajnosti možemo odbaciti hipotezu da imamo problem s heteroskedastičnosti. Test normalnosti distribucije (vidjeti prilog 7.) prikazuje da imamo problema s normalnošću distribucije jer je Doorink- Hansenov test 0. Temeljem provedenih testova možemo zaključiti da je regresija adekvatno postavljena stoga ne pokazuje problem autokorelacije i heteroskedastičnosti, dok s normalnošću distribucije imamo problema što je prihvatljivo zbog heterogenosti varijabli.

Prethodna regresijska jednadžba prikazuje normalizaciju po zavisnoj varijabli, odnosno po realnom bruto domaćem proizvodu. Dakle, možemo pretpostaviti da ako se parametar β_1, osobna potrošnja, poveća za 1% to će rezultirati povećanjem realnog BDP-a za 1,68%. S druge strane, ako se parametar β_2, realne bruto plaće povećaju za 1% to će rezultirati smanjenjem realnog BDP-a za 1,15% te ako pretpostavimo da će doći do povećanja parametra β_3, REER-a za 1% to će utjecati na smanjenje realnog BDP-a za 0,09%. U praksi, povećanje indeksa REER-a bi značilo da bi se dogodila deprecijacija hrvatske kune.

Prethodno navedeno možemo potvrditi empirijskom pozadinom (poglavlje 3. ovog rada), odnosno ovim istraživanjem je potvrđeno da postoji utjecaj osobne potrošnje na rast BDP-a (HGK, 2017). Ujedno je potvrđeno da će povećanjem plaća doći do njihovog smanjenja u udjelu BDP-a (Nestić, 2009) te da aprecijacijom nacionalne valute dolazi do smanjenja BDP-a (Habib et. al, 2016). Navedene relacije su moguće zbog raznih uzroka, primjerice, rastom plaća od 1% realni BDP će se smanjiti zbog odluke pojedinca o štednji, a ne potrošnji. Dok se dio pojedinca odlučuje na štednju, drugi dio se može odlučiti na potrošnju, što će utjecati na povećanje osobne potrošnje, a samim time i realni BDP će se povećati. Povećanje osobne potrošnje dovodi do povećanje potražnje za jeftinijim uvoznim proizvodima čime će domaća valuta aprecirati te će se smanjiti izvoz, a samim time će se smanjiti i BDP.

4.6. Kratki rok

Normalizacijom po realnom bruto domaćem proizvodom prikazano je da postoji dugoročna veza među varijablama. Ujedno, među varijablama postoji kratkoročna veza. U daljnjem tekstu bit će prikazan utjecaj nezavisnih varijabli na zavisnu varijablu u kratkom roku te koliko se brzo, u kojem vremenskom periodu, varijable vraćaju u početnu ravnotežu. Model u kratkom roku se može vidjeti u prilogu broj 4. Razdoblje prilagode komentirano je temeljem EC1 jednadžbi za svaku pojedinu varijablu. Na temelju dobivenih vrijednosti izračuna, vidjet ćemo u kojem se razdoblju varijable u dugom roku vraćaju u početnu ravnotežu te ćemo promatrati značajnost varijabli. Značajnost varijabli promatramo na temelju dobivenog modela, odnosno promatramo p i t vrijednosti te R^2 (koeficijent determinacije).

Prema gore navedenome, za zavisnu varijablu, realni BDP možemo zaključiti da se prilagođava u 4,92 razdoblju (prema izračunu: $1/(-0{,}203374)=4{,}92$). Kada promatramo ostale vrijednosti dane za ovu varijablu možemo zaključiti da se dugoročno ne prilagođava

ravnoteži. To možemo zaključiti na temelju p vrijednost koja je manja od 0.05, zatim na temelju t vrijednost koja je manja od 2, te R^2 čija je vrijednost niska, a iznosi 0,259013, dok Durbin-Watson iznosi 1,711625.

Sljedeća varijabla je osobna potrošnja koja se prilagođava u 10,18 razdoblju (prema izračunu: 1/(−0,0981932)=10,18). Promatrajući ostale vrijednosti: p vrijednost je veća od 0.05, a t vrijednost je manja od 2 te se zbog toga varijabla ne prilagođava dugoročnoj ravnoteži. R^2 je nizak 0,046898, a Durbin-Watson iznosi 1,569700.

Prilagodba promatrane varijable realnih bruto plaća će se prilagoditi u 5,38 razdoblju (prema izračunu: 1/(−0,185935)=5,38). Na temelju p vrijednosti koja je manja od 0.05 i t vrijednosti koja je manja od 2 zaključujemo da se zbog toga varijabla ne prilagođava dugoročnoj ravnoteži. R^2 je nizak 0,358948 , a Durbin-Watson iznosi 1,815376.

Posljednja promatrana varijabla je REER koji će se prilagoditi u 11,41 razdoblju (prema izračunu 1/0,0876446=11,41). Prema ostalim pokazateljima zaključujemo da se varijabla REER-a dugoročno ne prilagođava ravnoteži, a to nam pokazuje p vrijednost koja je manja od 0.05, a t vrijednost je manja od 2, R^2 je nizak 0,094140, a Durbin-Watson iznosi 1,537982.

4.7. Dekompozicija varijanci prognostičkih pogrešaka i impulsne funkcije

U ovom poglavlju osvrnut ćemo se na dekompoziciju varijanci prognostičkih pogrešaka te na impulsne funkcije varijabli koje su promatrane u ovoj analizi (realni BDP, osobna potrošnja, plaće te REER). Dekompozicija varijance nam pokazuje razdoblja sa pripadajućim postotcima koji nam objašnjavaju koliko svaka varijabla objašnjava samu sebe u vremenskim razdobljima u ovom slučaju za dvadeset vremenskih razdoblja.

U ovoj analizi promatrat ćemo dvadeset razdoblja, te smo sukladno modelu, realni BDP stavili kao zavinu varijablu. Za detaljan uvid u izračun dekompozicije varijance pogledati prilog 8. Iz izračuna je vidljivo kako zavisna varijabla u prvom razdoblju samu sebe objašnjava 100%, dok u posljednjem promatranom razdoblju sama sebe objašnjava sa 52,51%. Prema Woldovom redoslijedu, koji smo koristili kao kriterij redoslijeda varijabli kod dekompozicije varijance, poslije zavisne varijable je varijabla osobne potrošnje koja sama sebe u prvom promatranom razdoblju objašnjava s 0% što nam govori da ova varijabla nije

značajna. U posljednjem promatranom razdoblju, varijabla osobne potrošnje je objašnjenja sa 36,13%. Sljedeće varijable u nizu su varijabla realnih bruto plaća i varijabla REER-a koje su, kao i prethodna varijabla, u prvom razdoblju objašnjene s 0%. Dok su u dvadesetom razdoblju ove varijable objašnjene sa 11,28% (realne bruto plaće) i 0,07% (REER). Ako varijablu osobne potrošnje promatramo u preostalim razdobljima, varijabla sama sebe u sljedećem razdoblju sve više objašnjava. Primjerice, kao što samo prethodno naveli, u prvom razdoblju se objašnjava s 0%, u drugom razdoblju se objašnjava sa 4,07%, u petom razdoblju je objašnjena sa 18,82%, dok je u petnaestom razdoblju objašnjena sa 34,18%. Navedenim možemo zaključiti da će promjene osobne potrošnje u svakom sljedećem razdoblju biti značajnije. Do istog zaključka dolazimo i kod preostalih varijabli.

Varijablu realne bruto plaće kada promatramo kroz razdoblja, promjene kod ove varijable su značajnije što se broj razdoblja povećava, npr. u četvrtom razdoblju ova varijabla je objašnjena sa 4,57%, u osmom razdoblju je objašnjena sa 8,40%, četrnaestom razdoblju sa 10,49%, a u devetnaestom promatranom razdoblju je objašnjena sa 11,19%. Ako promatramo realni efektivni devizni tečaj (REER) kroz razdoblja, promjene koje se kod varijable događaju kroz razdoblja nisu značajna što je vidljivo i iz pripadajućih postotaka kod određenog razdoblja. Primjerice, u trećem razdoblju REER je objašnjen s 0,02%, u sedmom razdoblju je objašnjen s 0,05%, u petnaestom razdoblju je objašnjen s 0,07% te se do kraja promatranog vremenskog razdoblja ovaj postotak značajno ne mijenja. Možemo zaključiti da je varijabli REER potrebno druže vremensko razdoblje prilagodbe kako bi varijabla bila što značajnija. Na temelju provedene analize možemo zaključiti da će značajnije promjene, u odnosu na zavisnu varijablu, imati varijabla osobne potrošnje i varijabla plaća. U poglavlju 4.7. na temelju modela u kratkom roku, putem izračuna, vidjeli smo u koliko se razdoblja prilagođava pojedina varijabla. Do istog zaključka možemo doći ako promatramo impulsne funkcije istih varijabli (vidjeti prilog 9.).

Iz grafova impulsnih reakcija možemo vidjeti da jedinično povećanje osobne potrošnje će utjecati na povećanje realnog BDP-a, ali i povećanja realnih bruto plaća dok će imati negativan utjecaj na realni efektivni devizni tečaj. Nadalje, povećanje plaća od jednu jedinici će utjecati na smanjenje realnog BDP-a, a u 5,38 razdoblju varijabla plaće će se prilagoditi ravnoteži. Iz grafikona impulsnih funkcija, možemo vidjeti kako će povećanje plaća negativno utjecati na osobnu potrošnju, odnosno ona će se smanjiti. Razlog tome je moguća odluka pojedinca da povećani dio dohotka odlučiti uštedjeti. Posljednja varijabla, realni efektivni

devizi tečaj, ima ne toliko značajan negativni utjecaj na realni BDP, odnosno, deprecijacja realnog deviznog tečaja za 1% utjecat će na smanjenje realnog BDP-a za 0,09%, ali i na smanjenje osobne potrošnje i realnih bruto plaća.

4.8. Rezultati analize modela

Provedenom analizom koja je obuhvaćala kvartalne podatke od 2000. godine do 2014. godine, dobivenim rezultatima potvrđujemo teorijsku pozadinu te značajnost modela. Iz analize možemo zaključiti kako postoji dugoročna linearna veza među varijablama osobne potrošnje i realnog BDP-a te ova veza pozitivno utječe na gospodarsku sliku zemlje. Dok veza realnih bruto plaća, realnog efektivnog deviznog tečaja i BDP-a ima negativan utjecaj na gospodarsku sliku zemlje. Uz navedeno, analizom je utvrđeno ukoliko se osobna potrošnja poveća za 1%, realni BDP će se povećati za 1,67 %. Povećanja realnih bruto plaća za 1% utjecat će na smanjenje realnog BDP-a za 1,15 %, te ako se realni efektivni devizi tečaj poveća za 1%, odnosno ako nacionalna valuta deprecira, to će utjecati smanjenje BPD-a za 0,09 %.

Mogući razlozi prethodno navedenog ponašanja varijabli možemo povezati s odlukom pojedinca o kupnji ili štednji. Na povećanje osobne potrošnje utječe i povećanje plaća. Ukoliko se pojedincu plaća poveća on će se odlučiti na potrošnju te zadovoljenje osnovnih životnih potreba, ali će se odlučiti i na kupovinu luksuznih dobra. Ovime se osobna potrošnja povećava čime pozitivno utječe na realni BDP. Ukoliko se pojedincu plaća poveća i on odluči uštedjeti iznos za koji mu se plaća povećala, tada će se njegova osobna potrošnja smanjiti ili će ostati na istoj razini što će negativno utjecati na realni BDP, odnosno doći će do njegovog smanjenja. Dok, povećanje vrijednosti indeksa REER-a odgovara građanima, a izvoznicima ide na štetu jer ovakvo ponašanje tečaja kune dovodi do smanjenje izvoza, a povećava se uvoz čime se građanima pruža mogućnost kupnje jeftinih uvoznih proizvoda čime se negativno utječe na realni BDP.

S obzirom na malo unutarnje tržište za Republiku Hrvatsku bitno je buduće kretanje osobne potrošnje. Uz budući veći stupanj iskorištenosti sadašnjih proizvodnih potencijala može se očekivati odgovarajuća razina osobne potrošnje koja bi u budućnosti utjecala na daljnji gospodarski razvoj. Upravo je osobna potrošnja pokretač razvoja gospodarstva jer utječe na kretanje zaposlenosti, na agregatne izdatke, na investicije i štednju, a to je ono na što je

potrebno kako bi se gospodarska situacija u Hrvatskoj promijenila. Dugoročno, osobna potrošnja bi potaknula gospodarske tijekove, te u konačnici utjecala i na bruto domaći proizvod. Gospodarski tijekovi u Republici Hrvatskoj, nakon globalne ekonomske krize se polako mijenjaju u pozitivnom smjeru. Analize koje se iznose u javnost su optimistične, pa se trenutno u Republici Hrvatskoj očekuje rast gospodarske aktivnosti, tj. predviđa se rast osobne potrošnje uslijed rasta realnog raspoloživog dohotka kućanstva što proizlazi iz povoljnih kretanja na tržištu rada. Također, očekuje se rast izvoza te investicija, što će dodatno doprinijeti povećanju gospodarske aktivnosti. Ujedno se ističe potreba za provođenje strukturnih promjena koje bi dugoročno povećale potencijalnu stopu rasta hrvatskog gospodarstva.

Buduća kretanja osobne potrošnje u Hrvatskoj znatno utječu na gospodarske aktivnosti, ali i BDP. Prema tome, točnost provedene analize u ovom radu možemo potvrditi budućim optimističnim kretanjima osobne potrošnje i njenim utjecajem na gospodarske aktivnosti. Stoga je na nositeljima ekonomske politike transparentno provođenje ekonomskih politika radi očuvanja gospodarske stabilnosti Hrvatske.

5. ZAKLJUČAK

Jedan od najvažnijih indikatora razvijenosti gospodarstva neke zemlje je bruto domaći proizvod (BDP) koji se sastoji od četiri osnovne komponente: osobne potrošnje (C), investicijske potrošnje (I), državne potrošnje (G) i neto izvoza (NX). Kako bi ovaj pokazatelj bio što bolji potrebno je transparentno vođenje makroekonomske politike od strane nositelja politike.

Ovim radom se željelo pokazati kako će utjecaj pojedinih indikatora utjecati na rast realnog BDP-a Republike Hrvatske. Stoga su odabrane proizvoljne varijable (osobna potrošnja, realne bruto plaće, realni efektivni tečaj te realni BDP) u četrnaestogodišnjem razdoblju (2000. do 2014. godine).

U našem modelu realni BDP je bio zavisna varijabla te smo provedenom analizom potvrdili sljedeće. Osobna potrošnja u promatranom razdoblju ima značajniji utjecaj na rast realnog BDP-a, konkretno: ukoliko se osobna potrošnja poveća za 1% to će rezultirati povećanjem realnog BDP-a za 1,67%. Druge nezavisne varijable pokazale su negativan utjecaj na realni BDP, odnosno njihovo povećanje za 1% smanjit će realni BDP i do 1,15%. U analizi su uzeti i pokazatelji u vremenu kada je nastupila ekonomska kriza u Republici Hrvatskoj. Iz modela je vidljivo da su se sve varijable u određenim razdobljima vratile u ravnotežu te u posljednjim godinama promatranog razdoblja bilježe rast. Kako bi se njihov rast održao na održivoj razini potrebno je promišljeno djelovanje nositelja makroekonomske politike, prvenstveno kroz monetarnu i fiskalnu politiku.

Proučavanjem literature za ovu analizu uvidjelo se različito promatranje varijabli koje su se koristile u ovoj analizi. No, temeljem ove analize se došlo do istih rezultata kao i kod prijašnjih istraživanja, čime smo potvrdili teorijsku pozadinu i značajnost modela. Odnosno, zaključili smo da postoji dugoročna linearna veza među promatranim varijablama (realni BDP, osobna potrošnja, realne bruto plaće i REER).

Rezultati analize pokazali su da će povećanje osobne potrošnje imati pozitivan utjecaj na realni BDP. Dok ostale varijable, plaće i REER imaju značajan negativan utjecaj. Kako bi se njihov negativan utjecaj smanjio, smatram da treba uložiti napore u transparentnu politiku plaća, odnosno potrebno je smanjiti porezno opterećenje koje destimulira poslodavce

(preveliki troškovi rada) i radnike (premalene neto plaće). Smanjenjem poreza povećala bi se kupovna moć ljudi, a posljedično tome bi se povećala i osobna potrošnja koja vodi ka povećanju realnog BDP-a. Smatram da bi se trebala provoditi jača ekspanzivnu fiskalnu politiku nego što se trenutno provodi. Ukoliko se želimo osvrnuti na REER, možemo vidjeti da u promatranom razdoblju njegova vrijednost oscilira, te je u konačnici prisutna deprecijacija tečaja koja smanjuje realni BDP. Ukoliko bi se utjecaj REER-a na BDP promijenio, potrebno bi bilo aprecirati tečaj. Aprecijacija tečaja bi pozitivno utjecala na BDP jer bi se prvenstveno utjecalo na glavnu komponentu BDP-a, a to je izvoz roba i usluga. Dobivenim rezultatima provedene analize ne možemo odbaciti hipoteze koje smo postavili u uvodnom poglavlju ovog diplomskog rada.

Promatrajući trenutnu situaciju u hrvatskom gospodarstvu te prema onome što analitičari iznose u javnost, možemo vidjeti oporavak gospodarstva od posljedica globalne ekonomske krize; što je utjecalo na ne toliko značajno povećanje vrijednosti promatranih varijabli. Smatram da je u daljnjem periodu oporavka gospodarstva bitne napore usmjeriti na povećanje osobne potrošnje kao jedne od glavnih komponenti BDP-a jer jedino povećanje osobne potrošnje može imati značajniji dugoročni učinak na rast BDP-a što je i provedenom analizom potvrđeno.

Promišljenim djelovanjem nositelja politika smanjio bi se nastali jaz vrijednosti promatranih varijabli, ali bi se smanjilo i gospodarsko zaostajanje prvenstveno za zemljama članicama EU. No među nositeljima makroekonomske politike i dalje je kamen spoticanja transparentnost djelovanja politika, odnosno odabir kojom politikom nastupiti kako bi se očuvala gospodarska stabilnost Republike Hrvatske.

LITERATURA

A) KNJIGE

1. **ANDABAKA, A., ARČABIĆ, V., BARIĆ, V., BEG, M., BOGDAN, Ž., ČAVRAK, V., DRUŽIĆ, I., DRUŽIĆ, M., GELO, T., GLOBAN, T., KOVAČEVIĆ, Z., NADOVEZA, O., RAGUŽ KRIŠTIĆ, I., ROGIĆ DUMANČIĆ, L., SEKUR, T., SMOLIĆ, Š. (2016.)** *Gospodarstvo Hrvatske,* Ekonomski fakultet Sveučilišta u Zagrebu, Zagreb
2. **BABIĆ, M. (2004.)** *Makroekonomija,* Zagreb, MATE d.o.o.
3. **BABIĆ, M., BABIĆ, A., (2003.)** Međunarodna ekonomija, šesto izdanje, Zagreb, MATE d.o.o.
4. **BENIĆ, Đ. (2006.)** *Makroekonomija,* Zagreb, Školska knjiga
5. **BUŠELIĆ, M. (2017.)** *Suvremeno tržište rada,* Pula, Sveučilište Jurja Dobrile
6. **MANKIW, G. N. (2006**.) *Osnove ekonomije,* Zagreb, MATE d.o.o.
7. **PERIŠIN, I., ŠOKMAN, A., LOVRINOVIĆ, I. (2001.)** Monetarna politika, Fakultet ekonomije i turizma „Dr. Mijo Mirković“, Pula
8. **SHARMA, S., TOMIĆ, D. (2012.)** Ekonomska politika i makroekonomski management, Mikrorad, Zagreb
9. **STUTELY, R. (2007.)** *Ekonomski pokazatelji, Smisao ekonomije i ekonomskih indikatora,* Zagreb, Poslovni dnevnik, MASMEDIA, Prijevod: Sanda Tomičić

B) ČLANCI

1. **BENAZIĆ, M. (2006.)** *Fiskalna politika i gospodarska aktivnost u Republici Hrvatskoj: model kointegrcije, Izvorni znanstveni rad,* UDK 336.121:330.55(497.5), JEL Classification E60, C49, H30, Ekonomski pregled 57 (12) 882-918
2. **BROZ, T., BUTURAC, G., RAŠIĆ BAKARIĆ, I., SLIJEPČEVIĆ, S., PAVUN, D., SMILAJ, D. (2012.)** *Nepovoljna gospodarska kretanja,* Privredna kretanja i ekonomska politika,Aktualna ekonomska kretanja, 133/2012.
3. **CHIOMA, N., J. (2009.)** *Causal relationship between gross domestic product and personal consumption expenditure of Nigeria* Department of Sttatistics, Abia State University, Uturu, Abia State, Nigeria

4. **DENONA BOGOVIĆ, N. (2002.)** *Dugoročna obilježja osobne potrošnje u Republici Hrvatskoj,* Izvorni znanstveni rad, UDK 330.567.2 (497.5)
5. **ENGEL, R. F., GRANGER, C. W. J. (1987.)** *Co-Integration and Error Correction: Representation, Estimination and Testing,* Econometrica, Vol. 55., No 2., pp. 251-276
6. **HABIB, M., M., MILEVA, E., STRACCA, L. (No 1921/June 2016)** *The real exchange rate and economic growth: revisitng the case using external instruments,* Working paper, European Central Bank (ECB)
7. **JOHANSEN, S. (1991.)** *Estimination and Hypothesis of Cointegration Vectors in Gaussian Vector Autoregressive Models*, Econometrica, (59), 1551-1580
8. **JURIĆ, J. (2017.)** *Characteristic of personal consumption in Bosnia and Herzegovina*, University of Mostar, Faculty of Economics, Bosnia and Herzegovina, Preliminary communication, UDK: 330.567.22(497.6), Jel classification: EO1, E21
9. **LEVY – YEATI, E., STURZENEGGER, F. (2007.)** *Fear of Appreciation,* Policy Research Working Paper 4387, The World Bank, Latin America and the Caribbean Region Office oft he Cheif Economist
10. **MARIĆ, Ž. (2012.)** *Realni devizni tečaj i interno prilagođavanje (primjer bosne i hercegovine)*, Prethodno saopćenje, Ekonomski fakultet, Sveučilište u Mostaru
11. **NESTIĆ, D. (2009.)** *Plaće u Hrvatskoj: trendovi, problemi i očekivanja*
12. **RADMAN PEŠA, A., STANKOVIĆ, S., ŠTAJDUHAR, H. (2/2011)** *Istraživanje razine plaća u Hrvatskoj u odnosu na zemlje u regiji i zemlje EU,* Pregledni rad, Oeconomica Jadertina
13. **SHARPE, A., ARSENAULT, J.F., HARRISON P. (2008.)** *The Relationship between Labour Productivity and Real Wage Growth in Canada and OECD Countires,* Centre for the Study of Living Standards, Ottawa, Ontario
14. **STAVAREK, D. (2013.)** *Cyclical relationship between exchange rates and macro-fundamentals in Central and Eastern Europe,* Ecoonomics Research, ISSN 1331-677X print
15. **TOMIĆ, D. (2014.)** *What Information Tehnology Meant for Economic Prosperity of USA, Japan and Germany?,* Jurnal of Economic and Social Development, Vol 1, No 2

16. **ZDUNIĆ, S. (2003.)** *Relativne cijene, tečaj i konkurentnost Hrvatskog gospodarstva -uz desetu godišnjicu Stabilizacijskog programa-,* Izvorni znanstveni rad, Ekonomski pregled, 54 (11-12) 859-881

C) ELEKTRONIČKI IZVORI INFORMACIJA

1. **Državni zavod za statistiku** – www.dzs.hr (pristupljeno 20. veljače 2018.)
2. **Hrčak.srce** – www.hrcak.srce.hr (pritupljeno: 20. prosinca 2017.)
3. **Hrvatska narodna banka** – www.hnb.hr (pristuopljeno: 20. veljače 2018.)
4. **Investopedia** – www.investopedia.com (pristupljeno: 10. siječnja 2018.)
5. **JSTOR** –www.jstor.org (pristupljeno: 20. ožujka 2018.)
6. **Makroeconomics analysis, theory, policy, news** – www.macroeconomicanalysis.com (pristupljeno: 10. siječnja 2018.)
7. **Raiffeisen BANK** – www.rba.hr (pristupljeno:21. ožujka 2018.)
8. **The World Bank** – www.worldbank.org (pristupljeno: 3. ožujka 2018.)
9. **Zakon.hr** – www.zakon.hr (pristupljeno: 10. siječnja 2018.)

D) ZAKONI I PRAVNA REGULATIVA

1. **Zakon o radu**, NN 127/17, Zagreb

E) PUBLIKACIJE

1. **Hrvatska gospodarska komora, Sektor za financijske institucije, poslovne informacije i ekonomske analize, Odjel za makroekonomske analize** (ožujak 2017.) *Kretanje BDP-a u Hrvatskoj – napokon osjetniji rast*, Zagreb
2. **Državni zavod za statistiku (2013.)** *Statistički ljetopis,* Zagreb

F) SKRIPTA

1. **BELULLO, A. (2008.)** *VAR i VECM MODELI*, Skripta, Sveučilište Jurja Dobrile u Puli, Fakultet ekonomije i turizma „Dr. Mijo Mirković“, Pula

G) DOKTORSKA DIZERTACIJA

1. **TOMIĆ, D. (2012.)** *Utjecaj prihodovnih uvjeta razmjene na gospodarsku aktivnost Republike Hrvatske*, Sveučilište u Zagrebu, Ekonomski fakultet, Zagreb

POPIS TABLICA

Tablica 1. ADF (Argumented Dickey Fuller) test..... **33**

POPIS GRAFIKONA

Grafikon 1. Realni BDP Republike Hrvatske u razdoblju od 2000./Q1 do 2014/Q4 u milijardama HRK 8
Grafikon 2. Osobna potrošnja u Republici Hrvatskoj u razdoblju od 2000./Q1 do 2014./Q4 u milijardama HRK 12
Grafikon 3. Realne bruto plaće u Republici Hrvatskoj u razdoblju od 2000./Q1 do 2014/Q4 u tisućama HRK 17
Grafikon 4. Indeks realnog efektivnog deviznog tečaja u Republici Hrvatskoj za razdoblje od 2000./Q1 do 2014./Q4 21
Grafikon 5. Prikaz varijabli BDP-a (l_bdp_d11), osobne potrošnje (l_c_d11), realnih bruto plaća (l_place_d11) i realnog efektivnog tečaja (l_reer_d11) za razdoblje od 2000Q1 – 2014Q4 34

PRILOZI

Prilog 1. Apsolutne vrijednosti odabranih varijabli

Godine/Kvartali	Realni BDP	Osobna potrošnja	Realne bruto plaće	REER
00/1	60.002,44	36.242,93	6.500,19	118,92
00/2	64.164,28	37.969,08	6.381,57	118,24
00/3	68.443,21	35.713,46	6.333,59	115,91
00/4	64.605,41	41.006,23	6.428,01	116,60
01/1	61.663,44	38.061,31	6.408,18	114,19
01/2	67.022,29	40.388,87	6.421,95	110,83
01/3	70.898,70	36.025,75	6.399,93	109,99
01/4	66.464,73	42.655,59	6.446,88	111,39
02/1	64.420,47	41.016,02	6.398,99	112,59
02/2	69.538,09	43.370,64	6.690,94	111,13
02/3	75.749,38	39.122,74	6.773,72	110,34
02/4	70.299,42	46.251,05	6.818,08	111,13
03/1	68.474,67	42.953,87	6.732,15	111,55
03/2	74.272,68	45.165,33	6.840,33	110,36
03/3	79.392,35	40.439,73	6.958,45	109,77
03/4	73.430,20	47.866,81	6.966,73	111,09
04/1	71.610,25	44.357,44	6.984,18	108,51
04/2	77.566,57	46.901,93	7.168,37	107,13
04/3	82.318,85	42.293,08	7.291,29	106,74
04/4	76.141,79	49.916,66	7.223,31	108,01
05/1	73.087,77	45.652,25	7.088,12	105,92
05/2	81.315,18	49.194,09	7.293,56	104,43
05/3	86.236,88	44.201,35	7.341,20	105,83
05/4	79.806,75	51.634,88	7.286,21	105,74
06/1	77.698,99	47.222,96	7.226,75	103,76
06/2	84.339,41	50.095,97	7.451,10	102,31
06/3	90.232,87	45.851,55	7.508,90	103,26
06/4	83.509,50	53.720,45	7.594,76	104,22
07/1	83.019,32	50.725,86	7.609,96	102,94
07/2	89.485,07	53.354,44	7.694,11	102,20
07/3	94.138,06	48.783,67	7.780,27	101,90
07/4	86.431,06	56.357,87	7.698,18	100,71
08/1	85.826,90	53.088,27	7.711,94	99,20
08/2	92.123,67	54.926,26	7.719,47	97,91
08/3	95.403,24	49.209,33	7.697,94	97,77
08/4	86.969,58	54.743,08	7.874,38	98,93
09/1	78.429,94	48.451,94	7.842,42	99,35
09/2	84.548,75	50.255,08	7.784,59	97,78
09/3	88.066,54	46.327,76	7.808,38	97,65
09/4	82.672,65	51.236,37	7.760,86	96,92
10/1	76.283,21	46.284,87	7.664,33	98,19
10/2	81.839,23	48.714,24	7.675,30	99,77
10/3	87.742,70	46.864,45	7.698,45	100,26
10/4	82.175,38	51.498,66	7.668,87	101,65
11/1	75.365,38	46.178,23	7.520,53	101,97
11/2	82.015,76	49.033,68	7.608,60	101,29
11/3	88.135,18	47.109,99	7.682,17	103,28
11/4	81.601,55	51.668,98	7.656,08	104,59
12/1	74.422,84	45.785,43	7.576,42	106,82
12/2	79.630,08	47.474,80	7.444,10	104,86
12/3	86.331,26	45.374,11	7.436,46	104,96
12/4	79.578,22	49.472,78	7.335,56	104,48
13/1	73.099,08	44.504,80	7.332,00	104,21
13/2	79.255,72	47.470,38	7.352,63	104,06
13/3	85.869,99	45.255,93	7.329,26	103,64
13/4	78.732,49	48.633,13	7.332,92	104,78
14/1	72.626,96	44.279,94	7.381,94	104,80
14/2	78.648,56	47.224,98	7.332,85	104,19
14/3	85.443,89	44.737,92	7.399,35	105,41
14/4	78.969,93	48.347,79	7.363,81	107,30

Izvor: Obrada autorice prema podacima DZS (2018) i HNB (2018).

Prilog 2. Odabir lagova

VAR system, maximum lag order 4

The asterisks below indicate the best (that is, minimized) values

of the respective information criteria, AIC = Akaike criterion,

BIC = Schwarz Bayesian criterion and HQC = Hannan-Quinn criterion.

lags	loglik	p(LR)	AIC	BIC	HQC
1	753,53099		-26,197535	**-25,474195***	**-25,917098***
2	772,42179	0,00163	**-26,300778***	-24,998767	-25,795991
3	82,08492	0,25211	-26,074462	-24,193778	-25,345324
4	797,30508	0,01585	-26,046610	-23,587254	-25,093123

Izvor: Izračun autorice (Gretl 2017d).

Prilog 3. Odabir ranga

Johansen test:

Number of equations = 4

Lag order = 1

Estimation period: 2000:2 - 2014:4 (T = 59)

Case 3: Unrestricted constant

Log-likelihood = -1152,59 (including constant term: -1320,03)

Rank	Eigenvalue	Trace test	p-value	Lmax test	p-value
0	0,49307	78,454	[0,0000]	40,084	[0,0004]
1	**0,27923**	**38,370**	**[0,0035]**	**19,319**	**[0,0886]**
2	0,23071	19,051	[0,0125]	15,475	[0,0299]

Izvor: Izračun autorice (Gretl 2017d).

Prilog 4. VECM model (kratki rok)

Equation 1: d_l_bdp_d11

	Coefficient	*Std. Error*	*t-ratio*	*p-value*	
const	0,800110	0,178437	4,484	<0,0001	***
EC1	**−0,203374**	**0,0455620**	**−4,464**	**<0,0001**	***

Mean dependent var	0,003653	S.D. dependent var	0,013369
Sum squared resid	0,007681	S.E. of regression	0,011608
R-squared	0,259013	Adjusted R-squared	0,246013
rho	0,134284	Durbin-Watson	1,711625

Equation 2: d_l_c_d11

	Coefficient	*Std. Error*	*t-ratio*	*p-value*	
const	0,388333	0,229624	1,691	0,0963	*
EC1	**−0,0981932**	**0,0586320**	**−1,675**	**0,0995**	*****

Mean dependent var	0,003787	S.D. dependent var	0,015169
Sum squared resid	0,012720	S.E. of regression	0,014938
R-squared	0,046898	Adjusted R-squared	0,030177
rho	0,212737	Durbin-Watson	1,569700

Equation 3: d_l_place_d11

	Coefficient	*Std. Error*	*t-ratio*	*p-value*	
const	0,730177	0,128895	5,665	<0,0001	***
EC1	**−0,185935**	**0,0329121**	**−5,649**	**<0,0001**	*****

Mean dependent var	0,002014	S.D. dependent var	0,010382
Sum squared resid	0,004008	S.E. of regression	0,008385
R-squared	0,358948	Adjusted R-squared	0,347701
rho	0,066340	Durbin-Watson	1,815376

Equation 4: d_l_reer_d11

	Coefficient	*Std. Error*	*t-ratio*	*p-value*	
const	−0,344934	0,141031	−2,446	0,0176	**
EC1	**0,0876446**	**0,0360106**	**2,434**	**0,0181**	****

Mean dependent var	−0,001699	S.D. dependent var	0,009556
Sum squared resid	0,004798	S.E. of regression	0,009175
R-squared	0,094140	Adjusted R-squared	0,078248
rho	0,226008	Durbin-Watson	1,537982

Izvor: Izračun autorice (Gretl 2017d).

Prilog 5. Test autokorelacije

Equation 1:
Ljung-Box Q' = 1,10887 with p-value = P(Chi-square(1) > 1,10887) = 0,292

Equation 2:
Ljung-Box Q' = 2,79988 with p-value = P(Chi-square(1) > 2,79988) = 0,0943

Equation 3:
Ljung-Box Q' = 0,270584 with p-value = P(Chi-square(1) > 0,270584) = 0,603
Equation 4:
Ljung-Box Q' = 3,05855 with p-value = P(Chi-square(1) > 3,05855) = 0,0803

Izvor: Iračun autorice (Gretl 2017d).

Prilog 6. Test heteroskedastičnosti

Null hypothesis: no ARCH effect is present
Test statistic: LM = 0,947974
with p-value = P(Chi-square(1) > 0,947974) = 0,330236

Null hypothesis: no ARCH effect is present
Test statistic: LM = 0,812539
with p-value = P(Chi-square(1) > 0,812539) = 0,367371

Null hypothesis: no ARCH effect is present
Test statistic: LM = 0,290139
with p-value = P(Chi-square(1) > 0,290139) = 0,590131

Null hypothesis: no ARCH effect is present
Test statistic: LM = 0,702596
with p-value = P(Chi-square(1) > 0,702596) = 0,401913

Izvor: Izračun autorice (Gretl 2017d).

Prilog 7. Test normalnosti distribucije

Residual correlation matrix, C (4 x 4)

1,0000	0,66977	0,066630	-0,14913
0,66977	1,0000	0,13601	-0,15136
0,066630	0,13601	1,0000	0,21976
-0,14913	-0,15136	0,21976	1,0000

Eigenvalues of C

0,325874
0,71665
1,21716
1,74032

Doornik-Hansen test
Chi-square(8) = 48,7317 [0,0000]

Izvor: Izračun autorice (Gretl 2017d).

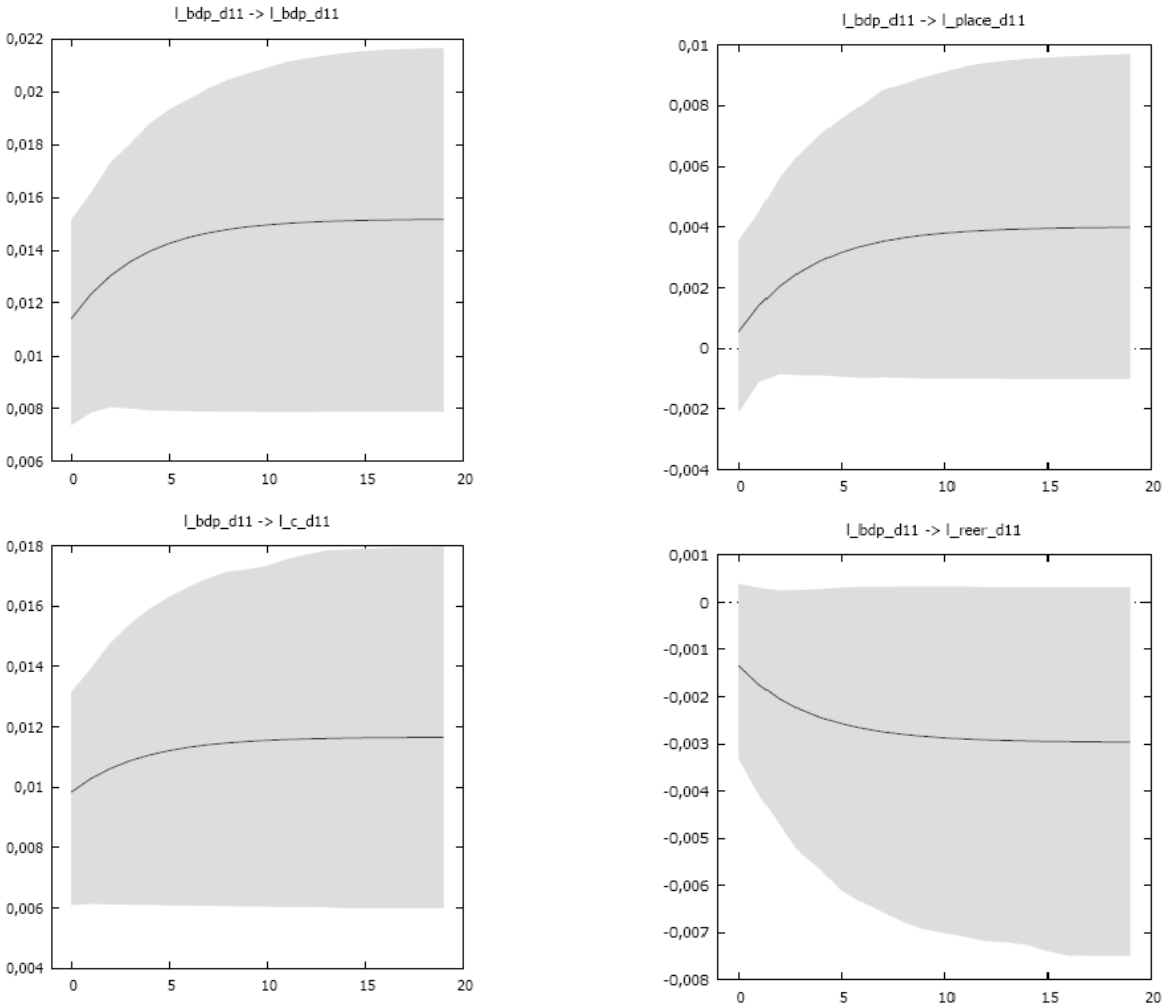
Prilog 8. Dekompozicija varijance

Decomposition of variance for l_bdp_d11

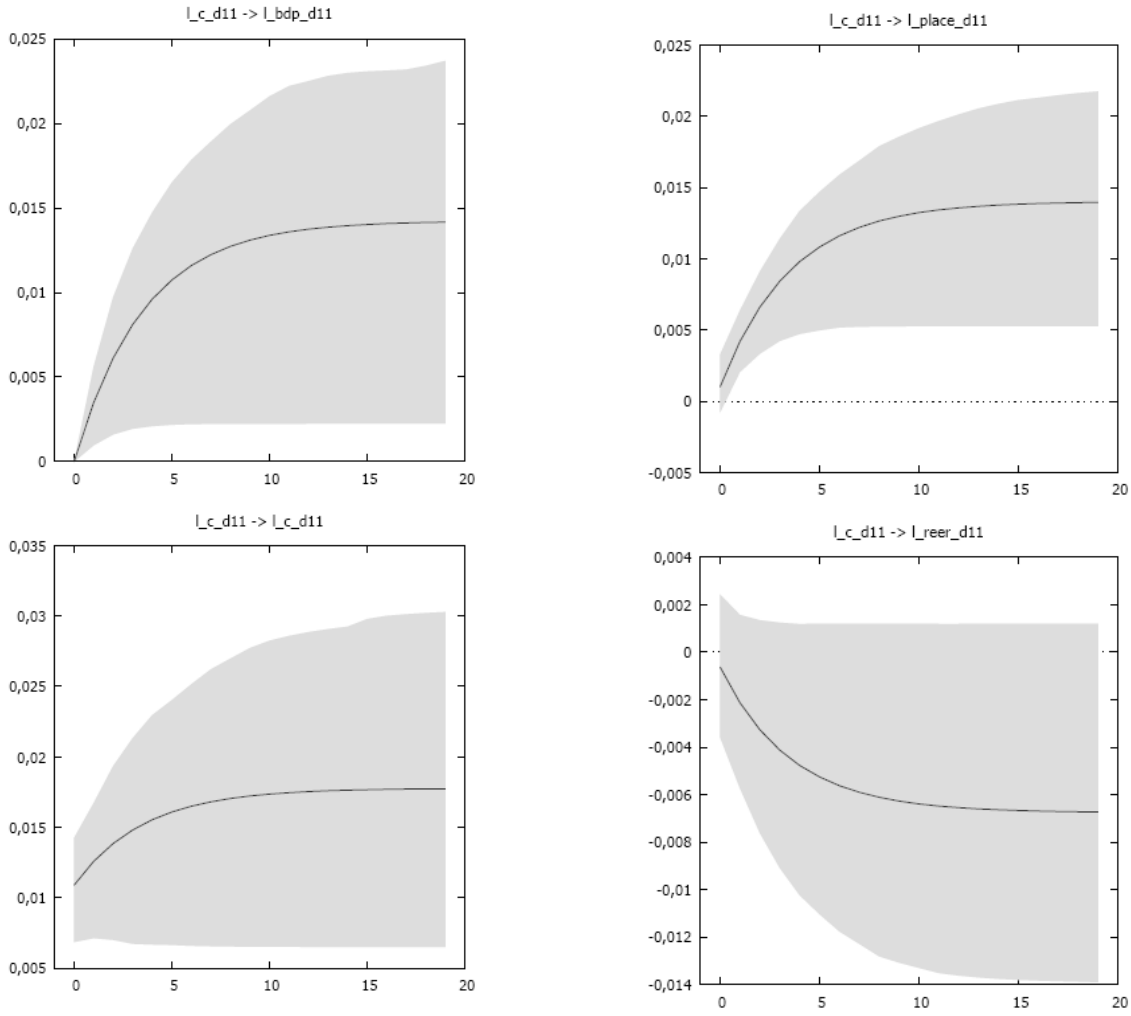
period	std. error	l_bdp_d11	l_c_d11	l_place_d11	l_reer_d11
1	0,0114099	100,0000	0,0000	0,0000	0,0000
2	0,0172728	94,6392	4,0789	1,2737	0,0082
3	0,0227488	87,3910	9,5939	2,9958	0,0193
4	0,0280695	80,7458	14,6501	4,5747	0,0295
5	0,0332296	75,2659	18,8196	5,8767	0,0379
6	0,0382011	70,8875	22,1510	6,9170	0,0446
7	0,0429662	67,4067	24,7994	7,7440	0,0499
8	0,0475195	64,6251	26,9159	8,4049	0,0542
9	0,0518646	62,3816	28,6229	8,9379	0,0576
10	0,0560104	60,5529	30,0143	9,3724	0,0604
11	0,0599689	59,0464	31,1605	9,7303	0,0627
12	0,0637533	57,7924	32,1147	10,0283	0,0646
13	0,0673769	56,7382	32,9168	10,2787	0,0662
14	0,0708528	55,8440	33,5972	10,4912	0,0676
15	0,074193	55,0787	34,1795	10,6730	0,0688
16	0,077409	54,4187	34,6816	10,8298	0,0698
17	0,0805109	53,8452	35,1180	10,9661	0,0707
18	0,0835082	53,3433	35,4999	11,0854	0,0714
19	0,0864092	52,9013	35,8362	11,1904	0,0721
20	0,0892216	52,5097	36,1342	11,2834	0,0727

Izvor: Izračun autorice (Gretl 2017d).

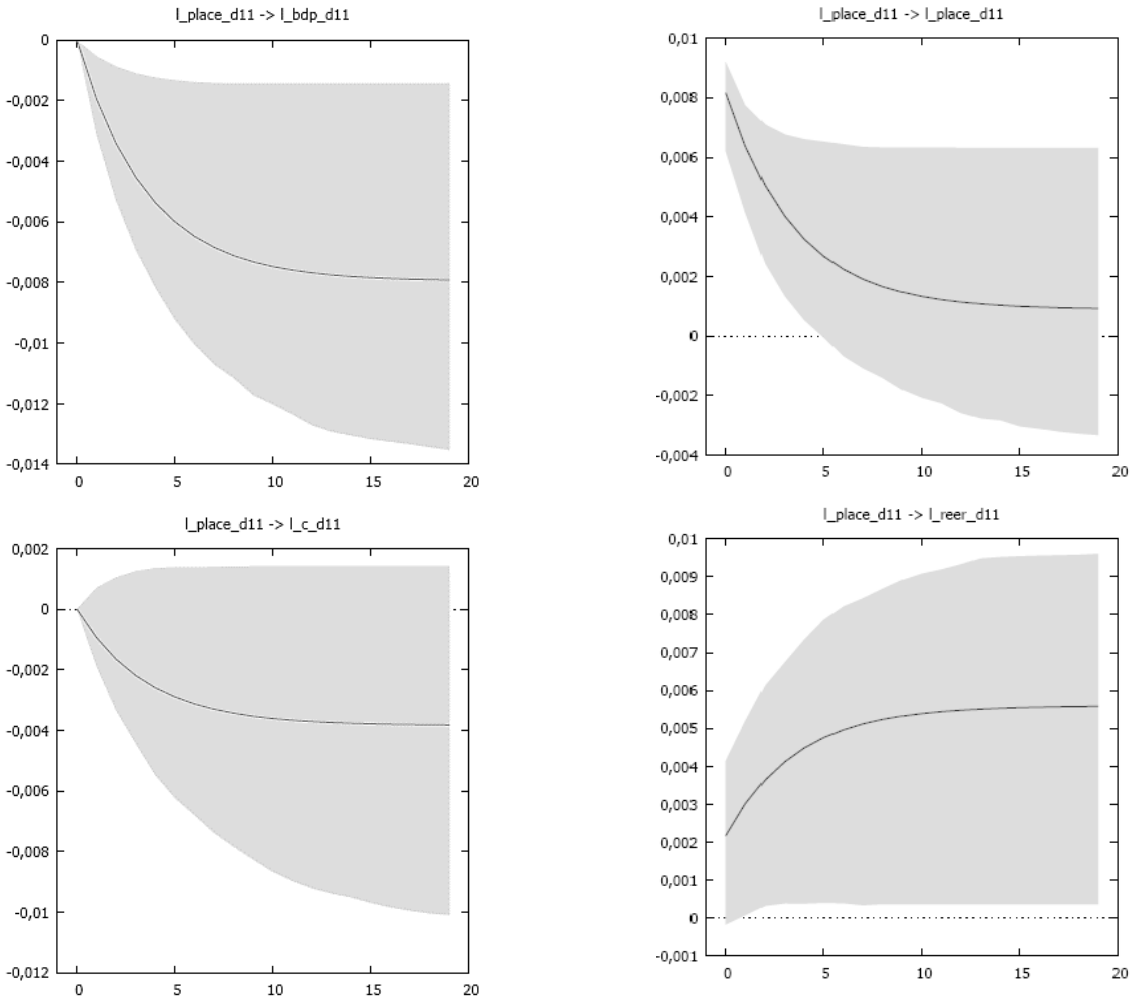
Prilog 9. Impulsne reakcije



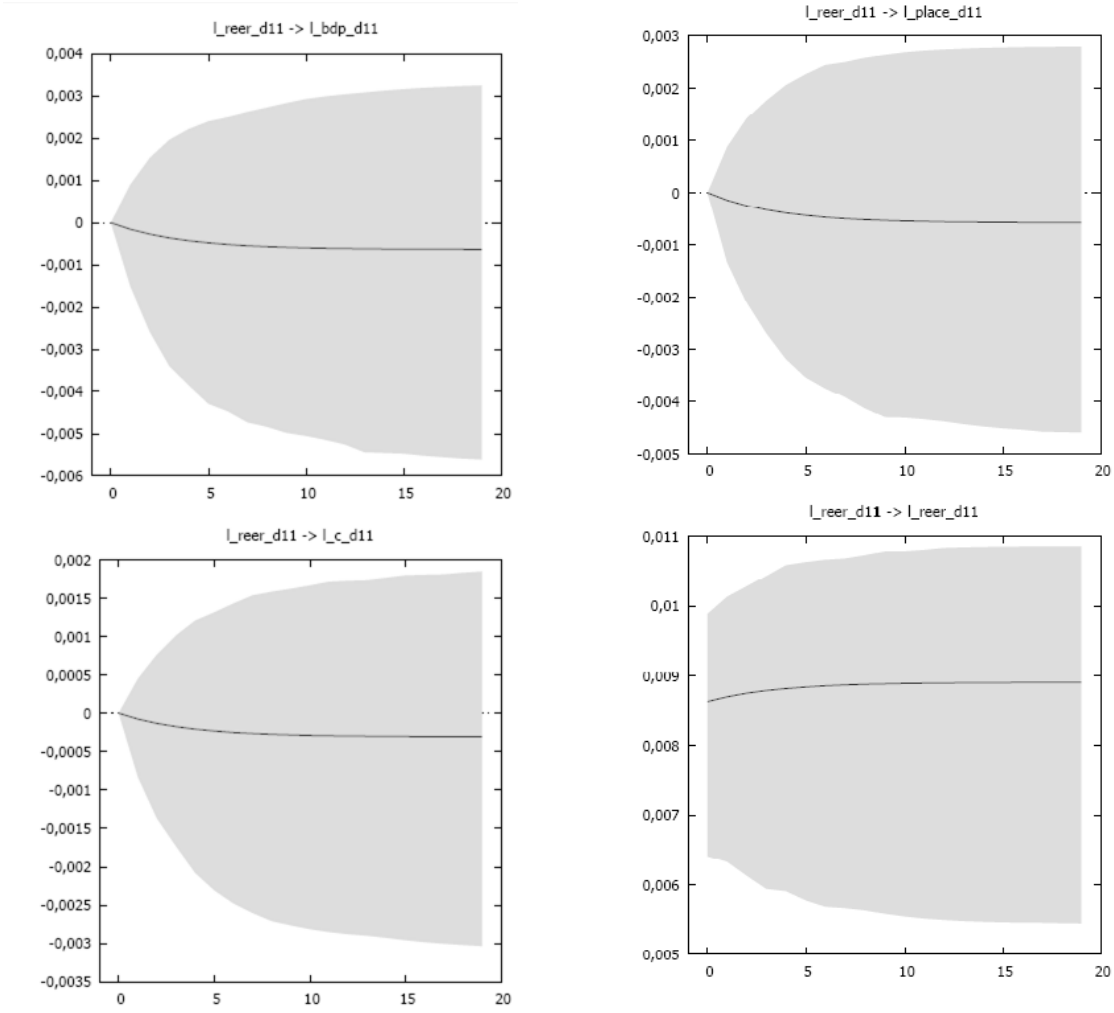
Izvor: Izračun autorice (Gretl 2017d).



Izvor: Izračun autorice (Gretl 2017d).



Izvor: Izračun autorice (Gretl 2017d).



Izvor: Izračun autorice (Gretl 2017d).

SAŽETAK

Martina Domšić

Analiza utjecaja izabranih makroekonomskih varijabli na BDP Hvatske

Bruto domaći proizvod se sastoji od četiri osnovne komponente: osobne potrošnje, državne potrošnje, investicija i neto izvoza. Osobnom potrošnjom podrazumijevamo alokaciju kućanstva na dobra i usluge. Odluka kućanstva o potrošnji uvelike ovisi o njihovom raspoloživom dohotku koji uvelike ovisi o visini plaće. Plaćom smatramo naknadu koju poslodavac isplaćuje zaposleniku. Visina plaće ovisi o situaciji na tržištu rada. Analizom izabranih makroekonomskih varijabli (osobna potrošnja, realne bruto plaće, REER) na BDP Hrvatske je prikazano da osobna potrošnji ima pozitivan utjecaj na BDP Hrvatske, dok ostale varijable imaju negativan utjecaj. Da bi se ostvario daljnji oporavak gospodarstva te se zadržao na održivoj razini potrebno je detaljno preispitati koncept makroekonomske politike, prvenstveno monetarne i fiskalne.

Ključne riječi: osobna potrošnja, plaće, REER, BDP, Hrvatska

SUMMARY

Martina Domšić

Analysis of Impact of Selected Macroeconomic Variables on the Croatian GDP

Gross domestic product consists of four basic components: private consumption, government consumption, investment and net exports. Personal consumption presents the allocation of households on goods and services. Decision household consumption is largely dependent on their disposable income, which largely depends on the amount of salary. Salary is compensation paid by the employer to the employee. Salary depends about the situation on the labor market. The analysis of selected macroeconomic variables (private consumption, real gross wages, REER) on the Croatian GDP has shown that personal consumption has a positive impact on the Croatian GDP, while other variables have a negative impact. In order to achieve further economic recovery and kept at a sustainable level, it is necessary to thoroughly examine the concept of macro-economic policies, especially monetary and fiscal.

Keywords: personal consumption, wages, REER, GDP, Croatia