UTJECAJ CIJENA NAFTE NA MAKROEKONOMSKE POKAZATELJE HRVATSKOG GOSPODARSTVA

Lolić Čipčić, Marina

Doctoral thesis / Disertacija

2021

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Split, Faculty of economics Split / Sveučilište u Splitu, Ekonomski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:124:147877

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET

MARINA LOLIĆ ČIPČIĆ

UTJECAJ CIJENA NAFTE NA MAKROEKONOMSKE POKAZATELJE HRVATSKOG GOSPODARSTVA

DOKTORSKA DISERTACIJA

SPLIT, 2020.

SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET

POSLIJEDIPLOMSKI SVEUČILIŠNI STUDIJ
EKONOMIJE I POSLOVNE EKONOMIJE

Marina Lolić Čipčić

UTJECAJ CIJENA NAFTE NA MAKROEKONOMSKE POKAZATELJE HRVATSKOG GOSPODARSTVA

DOKTORSKA DISERTACIJA

Mentor: prof. dr. sc. Đula Borozan

SPLIT, 2020.

UTJECAJ CIJENA NAFTE NA MAKROEKONOMSKE POKAZATELJE HRVATSKOG GOSPODARSTVA

Sažetak

U ovoj je disertaciji ispitan utjecaj cijena nafte na makroekonomske pokazatelje u Republici Hrvatskoj u periodu od 1995. do 2015. godine. Metodom vektorske autoregresije ispitan je utjecaj cijena na BDP, inflaciju, nezaposlenost, osobnu potrošnju i investicije, dok je modelom korekcije pogreške ispitan utjecaj cijena nafte na cijene naftnih derivata. U istraživanju su permutirana četiri različita pokazatelja cijena nafte kako bi se uvažila mogućnost linearnog kao i nelinearnog utjecaja cijena nafte na gospodarstvo. Rezultati istraživanja ukazuju na linearan pozitivan utjecaj cijena nafte na inflaciju kao i na činjenicu da cijene nafte ne predstavljaju u analiziranom periodu ograničavajući faktor rasta. Utjecaj cijena nafte na BDP je asimetričan pri čemu rast cijena nafte uzrokuje inicijalno negativnu reakciju BDP-a, a potom pozitivnu čime je, na kumulativnoj razini, utjecaj rasta cijena nafte na BDP gotovo neutralan. S druge strane, pad cijena nafte djeluje stimulativno na rast BDP, iako je navedeni utjecaj kratkoročan. Analiza je također pokazala da cijene nafte ne utječu statistički značajno na nezaposlenost odbacujući time hipotezu sektorske realokacije. Utjecaj cijena nafte na osobnu potrošnju nije statistički značajan iako je analiza pokazala strukturne promjene osobne potrošnje u smjeru rasta udjela troškova za prijevoz. Konačno, utjecaj cijena nafte na investicije je statistički značajno inicijalno pozitivan, a potom negativan, odražavajući važnost razlikovanja prirode i uzroka naftnih šokova kao i stanja gospodarstva u vrijeme apsorpcije istog. Kvalitativna i kvantitativna analiza istraživanja ukazuju na važnost kompleksnog pristupa tematici imajući u vidu specifičnosti promatranog gospodarstva kao i činjenicu da je priroda utjecaja cijena nafte na gospodarstvo podložna promjenama. Također iznimno je važno uzeti u obzir uzroke promjena cijena nafte jer oni koji su potaknuti pozitivnim cikličkim kretanjima nemaju ni približno negativne efekte kao oni potaknuti determinantama na strani ponude (proizvodnje) nafte.

Ključne riječi: *cijene nafte, makroekonomski pokazatelji, hrvatsko gospodarstvo, vektorska autoregresija, model korekcije pogreške*

IMPACT OF OIL PRICES ON MACROECONOMIC INDICATORS OF THE CROATIAN ECONOMY

Summary

This dissertation analyses the impact of oil prices on macroeconomic indicators in the Republic of Croatia between 1995. and 2015. The impact of oil prices on GDP, inflation, unemployment, personal consumption and investment was analysed using Vector AutoRegression methodology while Error Correction Model was used to analyse the impact of oil prices on fuel prices. The research included four different oil price measurements in order to allow for the possibility of a linear as well as a nonlinear nature of the oil prices impact on the economy. Research results imply a linear positive impact of oil prices on the inflation rate while oil prices do not seem the be the limiting factor of growth during the period under investigation. Oil prices asymmetrically affect GDP with the response of GDP to a rise in oil prices initially being negative, and then shortly positive, making the accumulated response of GDP to an oil price rise rather neutral. On the other hand, GDP reacts positively to an oil price decrease, although shortly. The analysis also revealed the resilience of the unemployment rate to oil price fluctuations discarding the sectoral reallocation hypothesis. The oil price impact on personal consumption was proven to be statistically insignificant although the analysis implied structural changes within the personal consumption category in favour of transportation costs growth. Finally, the impact of oil prices on investment was initially positive, and then negative, amplifying the importance of the nature and causes behind the oil price changes as well as the state of the economy at the time of the shock. Qualitative and quantitative analysis indicate the importance of a complex approach to the subject matter takin national specificities into account as well as the nature and causes of the oil shocks. Demand side driven oil shocks tend to have rather limited, even positive, influence on the real economy as oppose to supply side oil shocks.

Key words: *oil prices, macroeconomic indicators, Croatian economy, Vector AutoRegression (VAR), Error Correction Model (ECM)*

Mojim najmilijima…

bez vaše bezuvjetne podrške, pomoći i razumijevanja ova doktorska disertacija ne bi ugledala svjetlo dana.

Hvala vam od srca!

SADRŽAJ

1. UVOD 1

1.1. PROBLEM I PREDMET ISTRAŽIVANJA 1
1.2. CILJEVI ISTRAŽIVANJA 9
1.3. ISTRAŽIVAČKE HIPOTEZE 11
1.4. METODE ISTRAŽIVANJA 28
1.5. OČEKIVANI ZNANSTVENI DOPRINOS 30
1.6. STRUKTURA RADA 31

2. MAKROEKONOMSKI UČINCI KRETANJA CIJENA NAFTE 34

2.1. ENERGIJA I GOSPODARSKI RAST 34
2.1.1. Važnost energije s aspekta gospodarskog rasta 34
2.1.2. Uloga energije u teorijama rasta 38
2.1.3. Pregled istraživanja o uzročnosti energije i gospodarskog rasta 44
2.2. MEHANIZMI UTJECAJA CIJENA NAFTE NA MAKROEKONOMSKE POKAZATELJE 52
2.2.1. Implikacije promjena cijena nafte na gospodarski rast 52
2.2.2. Kretanje inflacije u odnosu na promjene cijena nafte 65
2.2.3. Mehanizmi utjecaja cijena nafte na nezaposlenost 70
2.2.4. Utjecaj cijena nafte na kretanje osobne potrošnje 79
2.2.5. Reakcije investicija na kretanje cijena nafte 86
2.2.6. Problem asimetrije utjecaja cijena nafte na gospodarstvo 89
2.2.6.1. Monetarna politika kao mogući izvor asimetrije 91
2.2.6.2. Troškovi prilagodbe kao mogući izvor asimetrije 92
2.2.6.3. Cijene naftnih derivata kao mogući izvor asimetrije 93
2.2.6.4. Ostali mogući izvor asimetrije 100
2.3. KLJUČNE KARAKTERISTIKE SVJETSKOG NAFTNOG TRŽIŠTA 101
2.3.1. Ponuda nafte 103
2.3.1.1. Ponuda nafte unutar OPEC-a 103
2.3.1.2. Ponuda nafte izvan OPEC-a 105
2.3.1.3. Proizvodnja nafte 106
2.3.2. Potražnja za naftom – izvedena potražnja 109
2.3.3. Kretanje cijena nafte 120
2.3.3.1. Naftni šokovi 123
2.3.3.2. Volatilnost cijena nafte 128

3. ANALIZA MAKROEKONOMSKIH POKAZATELJA HRVATSKOG GOSPODARSTVA 133

3.1. BRUTO DOMAĆI PROIZVOD KAO INDIKATOR REALNOG GOSPODARSKOG RASTA 133
3.2. INFLACIJA KAO MAKROEKONOMSKI POKAZATELJ 140
3.3. STOPA NEZAPOSLENOSTI KAO MAKROEKONOMSKI POKAZATELJ 152
3.4. OSOBNA POTROŠNJA KAO MAKROEKONOMSKI POKAZATELJ 160
3.5. INVESTICIJE KAO MAKROEKONOMSKI POKAZATELJ 166
3.6. ANALIZA TRŽIŠTA NAFTNIH DERIVATA 171

3.6.1. Cijene naftnih derivata ... 177
3.6.2. Porezi i trošarine na naftne derivate ... 181
3.6.3. Međunarodna usporedba cijena naftnih derivata ... 186

4. ISTRAŽIVANJE UTJECAJA CIJENA NAFTE NA MAKROEKONOMSKE POKAZATELJE HRVATSKOG GOSPODARSTVA ... 191

4.1. KONCEPTUALNI MODEL I FORMULACIJA EMPIRIJSKIH MODELA ISTRAŽIVANJA ... 191
4.2. METODOLOGIJA EMPIRIJSKOG ISTRAŽIVANJA ... 198
4.2.1. Opis korištenih statističko-ekonometrijskih metoda ... 198
4.2.1.1. Vektorski autoregresijski modeli i vektorski modeli korekcije pogreški . 199
4.2.1.2. Ispitivanje stohastičkih svojstava vremenskih nizova ... 203
4.2.1.3. Johansenova procedura i ispitivanje kointegracije ... 206
4.2.1.4. Testiranje Granger uzročnosti ... 208
4.2.1.5. Analiza stabilnosti modela ... 209
4.2.1.6. Inovacijska analiza ... 210
4.2.2. Operacionalizacija varijabli korištenih u istraživanju ... 212
4.3. PRELIMINARNA ANALIZA KORIŠTENIH VREMENSKIH NIZOVA ... 221
4.4. FORMULACIJA I TESTIRANJE EMPIRIJSKIH MODELA ... 223
4.4.1. Međuodnos cijena nafte i stope promjene bruto domaćeg proizvoda ... 223
4.4.2. Utjecaj cijena nafte na inflaciju ... 241
4.4.3. Implikacije promjena cijena nafte na kretanje nezaposlenosti ... 253
4.4.4. Promjene osobne potrošnje inicirane promjenama cijena nafte ... 261
4.4.5. Reakcija investicija na promjene cijena nafte ... 271
4.4.6. Asimetričnost utjecaja cijene nafte na cijene naftnih derivata ... 281
4.5. RASPRAVA O REZULTATIMA EMPIRIJSKOG ISTRAŽIVANJA ... 287
4.5.1. Kretanje stopa rasta bruto domaćeg proizvoda u odnosu na promjene cijena nafte 288
4.5.2. Odnos cijena nafte i inflacije ... 291
4.5.3. Reakcija nezaposlenosti na promjene cijena nafte ... 297
4.5.4. Uloga cijena nafte u kretanju osobne potrošnje ... 300
4.5.5. Utjecaj cijena nafte na investicije ... 306
4.5.6. Asimetričnost prilagodbe cijena naftnih derivata cijeni nafte ... 309
4.5.7. Ograničenja provedenog istraživanja i preporuke za daljnje istraživanje ... 313

5. ZAKLJUČAK ... 316
LITERATURA ... 324
POPIS TABLICA ... 358
POPIS GRAFIKONA ... 362
PRILOZI ... 365
ŽIVOTOPIS ... 369

1. UVOD

U uvodnom su dijelu predstavljene temeljne postavke istraživanja; eksplikacija problema i predmeta istraživanja, kao i ciljevi (znanstveni i aplikativni) istog, nakon čega su elaborirane istraživačke hipoteze, navedene znanstvene metode korištene u istraživanju, znanstveni doprinos provedenog istraživanja i kratak opis dispozicije rada.

1.1. PROBLEM I PREDMET ISTRAŽIVANJA

Bez energije nema gospodarskog rasta. Svaki vid ekonomske aktivnosti traži i korištenje određenog oblika energije; stoga, očekivano, cijene energije kao proizvodnog inputa determiniraju i mogućnosti rasta. U 21. stoljeću čovječanstvo je i dalje ovisno o neobnovljivim oblicima energije od kojih je, i dalje, najzastupljenija nafta. Shodno tome, a počevši od naftnih šokova 70ih godina prošlog stoljeća, znanstvenici još uvijek pokušavaju razotkriti način na koji cijene nafte utječu na gospodarstva, pri čemu je njihova znanstvena produktivnost u ovom području pozitivno korelirana s rastom realnih cijena nafte. Nafta je globalno najprodavanije dobro, a promjenjivost njenih cijena značajno utječe na makroekonomske pokazatelje svjetskih gospodarstava (*Ju et al., 2016*).

Krenuvši od naftnih kriza u 1970im godinama, s pionirskim radom *Jamesa Hamiltona (1983),* intenzivno se počeo ispitivati problem utjecaja cijena nafte na svjetska gospodarstva. Hamilton je ispitujući povezanost između porasta cijena nafte i gospodarskih recesija u Sjedinjenim Američkim Državama (SAD), u periodu od 1948. do 1980. godine, dokazao da povećane cijene nafte usporavaju gospodarski rast, te da su povećanja cijena nafte prethodila gotovo svim poslijeratnim gospodarskim recesijama u SAD-u snažno utječući na razinu outputa kao i na razinu (ne)zaposlenosti. Hamiltonovi zaključci široko su prihvaćeni i potvrđeni od strane cijelog niza autora *(Burbidge i Harrison, 1984; Santini, 1985; 1994, Gisser and Goodwin, 1986; Mork, 1989; Rotmberg i Woodford, 1996; Daniel (1997); Carruth, Hooker i Oswald, 1998; Hamilton, 2003 i dr.).*

Kasniji radovi, koji su uključili duže vremenske nizove (točnije, koji su za početak, uvrstili podatke iz 1980ih godina), ističu slabljenje veze između razine cijena nafte i makroekonomskih pokazatelja *(Lee et al., 1995; Hooker, 1996, Doroodian i Boyd, 2002).* No, znači li to da je Hamiltonova teza bila u potpunosti pogrešna i da cijene nafte nemaju nikakav utjecaj na output? Već na prvi pogled može se zaključiti da je malo vjerojatno da cijene najzastupljenijeg

svjetskog energenta nemaju nikakav utjecaj na gospodarstvo. Čini se, ipak, da se priroda te relacije promijenila.

Hamilton (2003) u svojim novijim istraživanjima zaključuje (potaknut prvenstveno radom *Hookera, 1996*) da, počevši od 1980ih godina, volatilnost (promjenjivost) cijena nafte ima značajniji utjecaj na ekonomsku aktivnost od same razine cijena nafte. Izrazita volatilnost cijena smanjuje utjecaj razine cijena zbog slabijeg efekta „iznenađenja" kada promjena cijene nastupi. Na koncu, Hamilton zaključuje da iako **nema dovoljno povijesnog iskustva da bi se mogao precizno modelirati odnos između promjene cijena nafte i rasta outputa**, između rasta cijena nafte (i pojave izrazite volatilnosti istih) i ekonomskog rasta u proteklim desetljećima postoji negativan odnos.

Među novijim utjecajnim radovima javljaju se i dokazi da **nije važan samo smjer i jačina naftnog šoka već i njegov uzrok**. Koristeći metodologiju vektorskog autoregresijskog modela (VAR, *engl. Vector AutoRegression*) na uzorku SAD-a, inicijalno *Kilian (2009)* razlikuje tri temeljne vrste naftnih šokova, ovisno o njihovom uzroku. Naftne cjenovne šokove *Kilian (2009)* dijeli na: šokove na strani ponude (*engl. oil-supply shocks*), šokove na strani potražnje koji se javljaju kao posljedica gospodarske aktivnosti (*engl. oil-demand shocks driven by global economic activity*) i šokove na strani potražnje koji su vođeni očekivanjima o budućim cijenama nafte, tj. špekulacijama (*engl. oil-specific demand shocks*). Ovakav pristup donosi posve nov uvid u prirodu utjecaja cijena nafte na gospodarstvo, a tiče se upravo šoka na strani potražnje vođenog snažnom ekonomskom aktivnošću; iako dolazi do rasta cijena nafte, u kratkom roku raste i output. Ovaj zaključak je dijametralno suprotan onome što se do tada smatralo uobičajenim utjecajem rastućih cijena nafte na gospodarski rast.

Literatura je, dakle, inicijalno bila bazirana na ključnu pretpostavku da promjene cijena nafte proistječu iz egzogenih promjena u ponudi nafte. U novije je vrijeme opće prihvaćen stav da su cijene nafte i pod utjecajem potražnje, a ne samo ponude (cf. *Hamilton, 2003; Barsky i Kilian, 2004*). Ipak, što je važno istaknuti, čak i kasnije studije koje su prihvatile Kilianov pristup dekompoziranja naftnih šokova ističu da se **većina literature o utjecaju cijena nafte na gospodarstvo, i dalje, koncentrira na nekolicinu industrijaliziranih zemalja, najčešće SAD** (*cf. Rafiq et al., 2009; Rasmussen i Roitman, 2011, Ran i Voon, 2012, Cashin et al., 2014*). Tako i *Narayan et al. (2014)* navode kako se van SAD-a još uvijek vrlo malo zna o tome pomažu li cijene nafte preciznije predvidjeti gospodarski rast, te zaključuju kako se opravdano

može konstatirati da se na svjetskoj razini i dalje vrlo malo zna o utjecaju cijena nafte na stope gospodarskog rasta. *Schubert i Turnovsky (2010)* također ističu kako su manje zemlje u razvoju suočene s ograničenim pristupom svjetskom financijskom tržištu, zbog čega bi, između ostalog, **efekt naftnih šokova mogao imati značajno različite efekte na ovakve zemlje u odnosu na razvijena svjetska gospodarstva**.

Tijekom proteklih trideset godina desetci znanstvenika pokušali su istražiti prirodu relacije koja bi kvantificirala utjecaj cijena nafte na makroekonomske pokazatelje pojedinih gospodarstava i to mahom na razvijenim gospodarstvima, pri čemu je glavnina studija rađena na primjeru SAD-a (*Karlsson et al., 2018*). Različite metode koje su korištene u njihovim istraživanjima izrodile su katkad značajnim, a katkad tek blagim razlikama u konačnim rezultatima. Zaključci analiza razlikovali su se ne samo kao posljedica korištenja različite metodologije, već i kao posljedica raznih globalnih utjecaja koji su se odrazili na promjene cijena nafte: pojava OPEC-a[1], recesije, ratovi u (među) zemljama izvoznicama nafte, meteorološke (ne)prilike, dostupne zalihe nafte, ulaganja u nove bušotine i sl.

Razlike među ekonomijama u vidu razlika u proizvodnoj strukturi, razlika u udjelu troškova energenata u nacionalnom dohotku, razlika u energetskoj intenzivnosti i energetskoj učinkovitosti proizvodnje, uvoznoj ovisnosti o nafti, različitim mehanizmima monetarne i fiskalne politike koji se primjenjuju u pojedinim državama (kao odgovor na naftne šokove), različiti porezni sustavi (koji utječu na razlike u cijenama naftnih derivata), pa čak i sociološke razlike među stanovništvom, sve to doprinosi dobivanju (često očekivanih) nerijetko vrlo različitih koeficijenata u ekonometrijskim modelima. Ovo su najvažniji razlozi zbog čega **do dan danas, unatoč ekstenzivnom istraživanju i promišljanju na ovu tematiku, nije osmišljen model koji bi bio primjenjiv na bilo koje gospodarstvo**, jer to jednostavno (zbog navedenih razlika među državama) nije ni moguće. Upravo zbog toga je izuzetno **važno istražiti iskustva pojedinačnih zemalja**.

Svjetska je literatura o utjecaju cijena nafte na gospodarstva kao i na pojedine makroekonomske pokazatelje, iako kod pojedinih tema brojna, **nerijetko oprečna i**

[1] Organizacija zemalja izvoznica nafte (*engl. Organization of the Petroleum Exporting Countries - OPEC*) je međunarodna organizacija koju tvore Alžir, Angola, Ekvador, Irak, Iran, Kuvajt, Libija, Nigerija, Katar, Saudijska Arabija, Ujedinjeni Arapski Emirati i Venezuela.

nedorečena, gotovo uvijek ostavljajući prostora za daljnje istraživanje. Tome zasigurno doprinosi činjenica da je sam utjecaj cijena nafte na gospodarstva različit jer, između ostalog, svako gospodarstvo podrazumijeva zaseban skup makroekonomskih indikatora koji se pod utjecajem subjekata specifičnih za tu ekonomiju (bilo da je riječ o stanovništvu, tvrtkama ili samoj državi) mijenjaju kreirajući jedinstveno makroekonomsko okruženje kao podlogu za daljnji ekonomski napredak. Prema *Jonesu i Leibyu (1996),* za zemlje OECD-a za koje postoje empirijska istraživanja utjecaja cijena nafte na makroekonomske pokazatelje (SAD, Ujedinjeno Kraljevstvo, Kanada, Francuska, Njemačka, Italija i Japan) rezultati istraživanja se razlikuju, a što je posljedica različitih industrijskih struktura, struktura ponude primarne energije, makroekonomskih i mikroekonomskih politika, struktura tržišta rada i formalnih i neformalnih institucija. U skladu s navedenim, autori ističu kako je **nerealno očekivati istovjetnu reakciju gospodarstava na bilo koji vanjski šok, pa tako i naftni.** Kako bi pojedino gospodarstvo moglo maksimizirati, odnosno, optimizirati svoj napredak, neizostavno je poznavanje okolnosti u kojima egzistira, bilo da su one egzogenog ili endogenog tipa, kako bi im se na vrijeme moglo prilagoditi i iskoristiti ih u svoju korist (makar se u slučaju povećanja cijena nafte korist može definirati kao minimiziranje negativnih efekata).

Gospodarstva različito reagiraju na naftne cjenovne šokove, s različitim vremenskim odmacima, kao i kumulativnim efektima, čak i kada se kroz kontrolne varijable apstrahiraju utjecaji mjera nacionalne politike (*Jones i Leiby, 1996*). U skladu s navedenim *Brown, Yücel i Thomson (2003)* ističu kako je **nužno značajno povećati broj istraživanja** kako bi se nositeljima politike mogle ponuditi jasnije preporuke glede optimalnih reakcija politike usmjerenih na smanjenje osjetljivosti gospodarstva na naftne cjenovne šokove. U slučaju Europske unije, čiji je član i Hrvatska, razlike u utjecaju naftnih šokova na države članice otežavaju implementaciju jedinstvenih mjera monetarne politike.

Intenzivan rast cijena nafte, najvažnijeg svjetskog energenta, kao i izrazita volatilnost cijena nafte, u trećem mileniju ponovno vraća u fokus istraživanja utjecaja cijena nafte na gospodarstvo *(Alvarez et al., 2011).* Kao posljedica identificiraju se specifični kanali utjecaja na pojedine makroekonomske pokazatelje; već poznat utjecaj na BDP se revidira, ispituje se utjecaj cijena nafte na inflaciju, devizni tečaj i razinu nezaposlenosti. Imajući sve navedeno u vidu, **do danas nije postignut akademski konsenzus oko pojedinih kanala utjecaja cijena nafte na gospodarstvo**.

Razlog fokusiranja na problem utjecaja cijena nafte na makroekonomske pokazatelje hrvatskog gospodarstva leži, izuzev u već navedenom, u nekoliko činjenica.

Kao prvo, **bez energije nema gospodarskog rasta** i upravo zato energetske krize koje u pravilu prati ekstreman porast cijena energije, predstavljaju ozbiljnu ugrozu svjetskog gospodarstva *(Čavrak, Gelo i Pripužić, 2006).* **Uvozno ovisna, otvorena gospodarstva, izrazito su podložna utjecajima i kretanjima na svjetskom tržištu,** različiti „šokovi" koji potresaju svjetsko tržište mogu se prenijeti unutar njihovih gospodarstava pri čemu je utjecaj šoka tim veći što je riječ o manjoj otvorenoj ekonomiji.

Kao drugo, prema izvješću Međunarodne energetske agencije (*International Energy Agency - IEA)*, **nafta je glavni svjetski energent i tako će**, s obzirom na postojeći stupanj tehnološkog razvoja i procjene korištenja energije iz ostalih izvora, **biti još najmanje sljedećih 50 do 100 godina** *(IEA, World Energy Outlook 2010, Factsheet, str. 1*). Sve popularniji alternativni, posebno obnovljivi izvori energije, još uvijek su alternativni samo po nazivu, kako navodi ista Agencija, jer ne predstavljaju alternativu nafti, već dopunu i mogućnost diverzifikacije energetskom portfelju pojedine ekonomije. Najznačajniji segment na kojem nafta zadržava svoju važnost je transport, pri čemu trenutne solucije koje se nude, poput transportnih sredstava na alternativni pogon, već duži niz godina prilično otežano rješavaju brojne prepreke koje im onemogućuju komercijalnu i ekonomski isplativu proizvodnju. Iako gubi svoj udio na tržištu u korist ugljena, uslijed iznimno visokih cijena, nafta i dalje zauzima najveći dio tržišta primarne energije s udjelom od 31,3% (*IEA*, *Key World Energy Statistics*, 2016., str. 6.). Istovremeno, projekcije Međunarodne energetske agencije ističu stabilan rast potražnje za energijom pri čemu fosilna goriva, većinski nafta, čine više od polovine očekivanog porasta potražnje za energijom.

Kao treće, u novijoj je povijesti **trend kretanja cijena nafte teško predvidiv** kao posljedica rasta volatilnosti cijena nafte. U periodu od 1947. do 1985. godine cijene nafte uglavnom su rasle (*Hamilton, 2008,* str. 35.), no počevši od 1986. godine naovamo, uzorak ponašanja cijena nafte se mijenja (u periodu od 1987. do 2000. standardna devijacija realnih cijena nafte iznosi 3,89, a nakon 2000. (do 2015.) čak 32,81!). Prisutna su značajna povećanja i smanjenja cijena nafte u kojima se očituje porast volatilnosti cijena (mjeren kao standardna devijacija cijene nafte u zadanom periodu). Volatilnost cijena nafte ne raste samo kao posljedica promjena u ponudi i potražnji za naftom, značajan je utjecaj i institucionalnih (OPEC), odnosno geopolitičkih

faktora, kao i špekulacija. **Rast volatilnosti cijena nafte uzrokuje veću neizvjesnost oko budućih cijena što vodi ekonomskoj nestabilnosti zemlje**, bilo da je ista uvoznik ili izvoznik nafte *(Narayan i Narayan, 2007).* Najnovija istraživanja utjecaja neizvjesnosti cijena nafte na realni rast, poput onog *Eldera i Serletisa* (*2009; 2010;* na uzorku SAD-a i Kanade) te *Rahman i Serletisa* (*2010*, na uzorku SAD-a), ističu negativan utjecaj neizvjesnosti cijena nafte na prosječne stope rasta realne ekonomije. Gotovo je izgledno da će cijene nafte, koje će kroz buduće razdoblje uravnotežiti tržište nafte, biti više od trenutnih odražavajući rastuću neosjetljivost kako ponude, tako i potražnje za naftom (*Arezki et al.*). Dok svjetski stručnjaci predviđaju buduće razine cijena nafte u prilično širokom rasponu, ono što se može tvrditi gotovo sigurno jest da će **volatilnost cijena rasti** *(Özbek i Özlale, 2010).*

Kao četvrto, Hrvatska je sve više i više uvozno ovisna o nafti pri čemu upravo tekuća **goriva čine najveći dio uvoza energenata**, a k tome je i domaća komponenta proizvodnje nafte daleko manja u odnosu na uvoz nafte (*Energetski Institut Hrvoje Požar, Uvoz energije u Hrvatsku, 1945.-2007., str. 50*). Ekonomijama koje su visoko uvozno ovisne o nafti ista predstavlja važan činitelj gospodarskog rasta (*Wang, 2013*). **Uvozna ovisnost o nafti i naftnim derivatima** pokazuje uzlazni trend i trenutno iznosi gotovo **90%** ukupne potrošnje tekućih goriva **u Europi** *(Finley, 2012; European Commission, 2017, EU energy in figures).* Ovo je u kontekstu geografskog područja istraživanja važno iz razloga što su **manje razvijene zemlje u pravilu više uvozno ovisne o nafti od razvijenih.** Iz toga slijedi da su i efekti promjene cijena tako važnog energenta različiti, posebice u dugom roku *(Schubert i Turnovsky, 2010).*

I, kao peto, **sustavna istraživanja ovog tipa koja se bave uvozno ovisnim ekonomijama u razvoju općenito su vrlo rijetka** *(Doğrul i Soytas, 2010; Jobling i Jamasb, 2017)),* a sustavna ispitivanja spomenutih relacija **na uzorku Republike Hrvatske gotovo da ne postoje.** Ovo je važno jer, kako ističe *Abeysinghe (2001)*, utjecaj **cijena nafte na gospodarski rast možda i nije toliko značajan za ekonomije poput SAD-a, no u slučaju otvorene ekonomije može biti od ključne važnosti.** U istom kontekstu i *Rafiq et al. (2009)* navode da manje razvijena gospodarstva u pravilu imaju više stope nezaposlenosti, manje razvijena financijska tržišta kao i lošiju energetsku infrastrukturu. Nužno je ovome dodati i da **post-tranzicijske ekonomije karakteriziraju viši pokazatelji energetske intenzivnosti** (pokazatelj utroška energije po jedinici BDP-a) **negoli je to slučaj kod razvijenih**, što dodatno problematizira bezuvjetno prihvaćanje rezultata studija vršenih na uzorku razvijenih zemalja. Upravo smanjena energetska

intenzivnost razvijenih ekonomija može ponuditi odgovor na pitanje smanjene osjetljivosti na promjene cijena nafte, što nije nužno slučaj kod zemalja u razvoju *(Özbek i Özlale, 2010).*

Godine 2006., *Čavrak, Gelo i Pripužić* (2006) analiziraju utjecaj cijena energenata (općenito) u svijetu i Hrvatskoj, te njihov utjecaj na gospodarstvo u cijelosti. Autori konstatiraju kako bi povećanje cijena energije (svih vidova u prosjeku) smanjilo hrvatski BDP i povećalo cijene.

Cota (2007) u svom radu nudi pregled istraživanja utjecaja cijena energenata na ukupnu privrednu aktivnost osvrćući se pri tom i na relevantna strana istraživanja o utjecaju cijena nafte na gospodarstvo. U zaključku ističe; ***„Kakve bi posljedice rast cijena energenata (poglavito nafte) imao na privrednu aktivnost u Hrvatskoj, ..., do sada nije sustavno istraženo."*** *(Cota, 2007, str. 115),* te dodaje da se može isključivo hipotetski nagađati kakve bi spomenute posljedice mogle biti na temelju pregleda dosadašnjih istraživanja na ostalim gospodarstvima.

Krtalić i Benazić (2008) objavljuju istraživanje o usporedbi inflacije u SAD-u, EU i Hrvatskoj (RH) pri tom razmatrajući cijene nafte kao katalizator rasta inflacije. Poseban osvrt autori nude na monetarnu politiku Sustava federalnih rezervi (FED), Europske središnje banke (ESB) i Hrvatske narodne banke (HNB), nudeći usporedbu kanala djelovanja monetarne politike s posebnim naglaskom na kanal kamatne stope koji predstavlja ključni monetarni mehanizam u slučaju FED-a i ESB-a, dok se u slučaju Hrvatske, prema njihovom mišljenju, nedovoljno/neadekvatno koristi. U Hrvatskoj se, smatraju, preferira kontrola deviznog tečaja (primarno zbog visoke uvozne ovisnosti i euroizacije); sukladno tome, sugeriraju da se uslijed daljnjeg rasta cijena nafte inflatorni pritisci ublaže aprecijacijom deviznog tečaja. Učinak deviznog tečaja na stimulaciju gospodarske aktivnosti prilično je nejasan, što se da iščitati iz postojećih istraživanja na tu temu *(Lang i Krznar, 2004; Vizek, 2007; Erjavec i Cota, 2003),* stoga su upitni i efekti aprecijacije deviznog tečaja na gospodarstvo (poglavito zbog prevelike zaduženosti).

Valja spomenuti i *doktorsku disertaciju Tomislava Gela iz 2008. godine* u kojoj je autor ispitao utjecaj svjetskih energetskih šokova na gospodarstvo, osvrćući se samo u pojedinim segmentima na cijene nafte. Autor pak zaključuje da realne cijene nafte ne utječu negativno na kretanje BDP-a, što je u potpunoj suprotnosti s postojećim teorijskim spoznajama, a što predstavlja dodatnu motivaciju za provjeru spomenute tvrdnje alternativnim metodama.

Na temu međuodnosa potrošnje energije i gospodarskog rasta javljaju se u međunarodnim okvirima brojni članci i studije. Glavnina tih studija dokazuje postojanje veze, ali ono oko čega još uvijek ne postoji znanstveni konsenzus je smjer uzročnosti; stimulira li potrošnja energije gospodarski rast, ili vrijedi obratno? Godine 2009. *Žiković i Vlahinić-Dizdarević* objavili su istraživanje o međusobnom utjecaju potrošnje energije i gospodarskog rasta na uzorku od 22 male europske države (uključujući i Hrvatsku). Istraživanje pokazuje kako kod manje razvijenih zemalja potrošnja energije stimulira gospodarski rast, dok je kod razvijenih zemalja situacija obratna (gospodarski rast potiče potrošnju energije). **Iako se istraživanje nije bavilo pitanjem cijena nafte**, zanimljivo je što je situacija **u slučaju Hrvatske** analogna onoj kod razvijenih zemalja, i.e. gospodarski rast stimulira potrošnju energije. Ovaj je **oprečni rezultat** prije svega rezultat tranzicije i deindustrijalizacije koje je iskusilo domaće gospodarstvo, ali, što je važnije, **implicira značaj istraživanja pojedinog gospodarstva uzimajući s rezervom iskustva ostalih zemalja sličnih karakteristika.** Problemom međuovisnosti potrošnje energije i gospodarskog rasta u Hrvatskoj bave se još dva novija istraživanja iz 2013. godine; istraživanje *Đule Borozan*, te istraživanje *Pavla Jakovca.* Dok se zaključci *Jakovca (2013)* koji tvrdi da gospodarski rast Granger uzrokuje potrošnju energije u velikoj mjeri podudaraju s onima *Žiković i Vlahinić-Dizdarević (2009)*, *Borozan (2013)* zaključuje upravo suprotno.

Naslanjajući se na zaključke *Čavraka, Gele i Pripužića (2006),* kao i na vlastita dotadašnja istraživanja, *Krtalić i Benazić (2010)* analiziraju utjecaj cijena nafte na inflaciju u Hrvatskoj konstatirajući kako porast cijena nafte pozitivno utječe na cijene, a negativno pak na gospodarsku aktivnost koju u svom istraživanju mjere indeksom industrijske proizvodnje. I sami **autori ističu kako bi se potpuni uvid u učinke promjene cijena nafte na hrvatsko gospodarstvo dobio tek analiziranjem svih relevantnih kanala utjecaja cijena na hrvatsko gospodarstvo.**

Revidiranjem akademskog opusa domaćih autora o tematici utjecaja cijena energenata i same energije na gospodarstvo evidentan je **golem prostor za daljnje istraživanje** kako bi se, prije svega, identificirali kanali kojima se svjetske cijene nafte prelijevaju u pore hrvatskog gospodarstva i, posljedično, kvantificirale zamijećene veze.

Sukladno dosada navedenom, a imajući u vidu prije svega da gospodarstva različito reagiraju na naftne cjenovne šokove, da do danas nije postignut akademski konsenzus oko pojedinih kanala utjecaja cijena nafte na gospodarstvo, te da su sustavna istraživanja ovog tipa koja se

bave ekonomijama u razvoju općenito vrlo rijetka (a na uzorku Republike Hrvatske gotovo da niti ne postoje), ***problem istraživanja*** se ogleda u nedovoljnoj teorijskoj i empirijskoj spoznaji o utjecaju cijena nafte na makroekonomske pokazatelje gospodarstva posebno kod post-tranzicijskih zemalja. Nedovoljno poznavanje mehanizama kojima se utjecaj cijena nafte prelijeva na ključne makroekonomske pokazatelje, prije svega na gospodarski rast (izražen stopom rasta realnog BDP-a), implicira potrebu za daljnjim teorijskim i empirijskim istraživanjima ovoga područja.

U skladu s navedenom problematikom istraživanja može se definirati i ***predmet istraživanja***, a to je teorijsko i empirijsko testiranje utjecaja cijena nafte na makroekonomske pokazatelje hrvatskog gospodarstva. Nužno je prvenstveno sistematizirati i klasificirati postojeća istraživanja utjecaja cijena nafte na makroekonomske pokazatelje, ali i steći nova saznanja, što može služiti kao smjernica nositeljima politike u vidu postizanja cilja adekvatne stope gospodarskog rasta. Problematika predloženog istraživanja je aktualna, slijedi svjetske trendove i s novim spoznajama doprinosi postojećim saznanjima, nudeći preispitivanje poznatih teorijskih okvira na dosada neadekvatno istraženom uzorku. Rezultati istraživanja bi stoga mogli, i trebali, biti od izuzetne važnosti za post-tranzicijske zemlje (ovisne o uvozu nafte) općenito.

1.2. CILJEVI ISTRAŽIVANJA

S obzirom na prethodno iznesenu problematiku, ciljeve istraživanja moguće je podijeliti na znanstvene ili spoznajne i empirijske, odnosno aplikativne.

Znanstveni/spoznajni ciljevi bi se mogli navesti kako slijedi:

- eksplikacija i teorijska sistematizacija determinanti cijena nafte,
- klasifikacija, sistematizacija i kritički osvrt na postojeća istraživanja o utjecaju cijena nafte na gospodarstvo,
- eksplikacija međuovisnosti cijena nafte i ključnih makroekonomskih pokazatelja: BDP-a, inflacije, nezaposlenosti, potrošnje i investicija,
- oblikovanje konceptualnog modela za utvrđivanje zakonitosti i smjera veze između cijena nafte i makroekonomskih pokazatelja, imajući u vidu cjelovitiji sustav promatranih međuodnosa varijabli, kao i pojedinačan utjecaj na svaki promatrani makroekonomski pokazatelj, kao i

- ukazivanje na ograničenja prilikom provođenja ovakve vrste istraživanja.

Empirijski/aplikativni ciljevi podrazumijevaju svojevrsnu primjenu novih teorijskih spoznaja, a moguće ih je navesti na sljedeći način:

- empirijsko testiranje i utvrđivanje smjera i intenziteta veze između cijena nafte i odabranih makroekonomskih pokazatelja u Republici Hrvatskoj: bruto domaćeg proizvoda, inflacije, nezaposlenosti, potrošnje i investicija,
- permutiranje četiri različita pokazatelja cijena nafte s ciljem identifikacije onog koji najbolje objašnjava reakciju hrvatskog gospodarstva na cjenovne naftne šokove,
- kompariranje rezultata utjecaja cijena nafte na hrvatsko gospodarstvo, kao reprezentanta post-tranzicijske zemlje u razvoju, u odnosu na rezultate postojećih istraživanja o utjecaju cijena nafte na makroekonomske pokazatelje „zapadnih“ gospodarstava, te
- temeljem rezultata empirijske analize, pomoć nositeljima politike u vidu sistematizacije spoznaja o utjecaju cijena nafte na makroekonomske pokazatelje hrvatskog gospodarstva s ciljem olakšavanja donošenja prikladnih ekonomskih politika na nacionalnoj razini.

Kako je već istaknuto, istraživanja utjecaja cijena nafte na pojedine makroekonomske pokazatelje rađena su mahom na ekonomsko jakim svjetskim gospodarstvima (primarno SAD) iz čega slijedi kako bi istraživanje na post-tranzicijskom, uvozno ovisnom gospodarstvu, poput hrvatskog, ponudilo nova teorijska i empirijska saznanja o utjecaju cijena nafte na gospodarstvo općenito. Ovaj cilj nastojat će se postići razvojem modela kojim će se obuhvatiti relevantne varijable u istraživanju utjecaja cijena nafte na gospodarstvo, s, kako je već rečeno, potencijalnom primjenom na otvorena gospodarstva u razvoju općenito.

Provedena istraživanja nisu dovoljno precizna u definiranju kanala i mehanizama utjecaja cijena nafte na gospodarstvo. S druge strane, važno je imati na umu izrazito visoku promjenjivost cijena nafte, kao i očekivanja da će se takav trend nastaviti u budućnosti. Kao posljedica, i dalje je nejasno kakva bi trebala biti uloga nositelja ekonomske politike kako bi se smanjili negativni učinci visoke volatilnosti i rasta cijena nafte. Iz tog razloga neophodno je nositeljima makroekonomske politike pobliže pojasniti implikacije promjena cijena nafte na uvozno ovisno gospodarstvo u razvoju kako bi se iste mogle uzeti u obzir prilikom donošenja odluka (primjerice o visini trošarina na naftne derivate ili pak o donošenju mjera monetarne politike). Iako postojeće studije (na razvijenim gospodarstvima) ističu ograničen utjecaj cijena nafte na makroekonomske pokazatelje, očekivanja rasta volatilnosti cijena nafte u dugom roku

dodatno potenciraju važnost implikacija istaknutih zaključaka za trenutne, kao i buduće nositelje politike.

1.3. ISTRAŽIVAČKE HIPOTEZE

Kako bi se prethodno iznijeta problematike istraživanja adekvatno empirijski ispitala, postavljene su hipoteze s ciljem olakšavanja razumijevanja međusobno isprepletenih odnosa (i mehanizama) makroekonomskih pokazatelja i cijena nafte. Na ovom je mjestu također nužno istaknuti doprinos ovog istraživanja koje promatra utjecaj cijena nafte na odabrane makroekonomske pokazatelje u multivarijantnom okruženju. Navedeni je pristup odabran s ciljem identifikacije transmisijskih mehanizama naftnih cjenovnih šokova na odabrane makroekonomske pokazatelje, odnosno ciljem detektiranja eventualnog indirektnog utjecaja cijena nafte na ciljani pokazatelj posredstvom preostalih varijabli u modelu. U nastavku slijedi teorijska elaboracija predloženih hipoteza, dok su konceptualni model istraživanja i ekonometrijski modeli temeljem kojih je izvršena empirijska provjera postavljenih istraživačkih hipoteza navedeni u sklopu poglavlja *4.1. Konceptualni model i formulacija empirijskih modela istraživanja* te grafički ilustrirani Shemom 1.

H1: Promjene cijena nafte statistički značajno negativno utječu na stopu rasta bruto domaćeg proizvoda hrvatskog gospodarstva.

Naftni šokovi u 1970im godinama, koji su pokrenuli gospodarske recesije diljem svijeta, dali su povoda prvim značajnijim istraživanjima utjecaja cijena nafte na gospodarstvo. Među prvim studijama utjecaja cijena nafte na gospodarstvo mogu se istaknuti one *Rasche i Tatoma (1977), Morka i Halla (1980), te Darbya (1982).* Nešto kasnije studije *(Gisser i Goodwin, 1986; Burbidge i Harrison, 1984)* potvrdile su njihove zaključke o postojanju inverzne veze između porasta cijena nafte i gospodarskog rasta (gospodarski rast podrazumijeva rastuće stope BDP-a, dok gospodarski pad podrazumijeva njegove negativne stope rasta).

Jedna od najznačajnijih studija toga vremena je svakako, u uvodnom dijelu već navedena, *Hamiltonova* iz 1983. godine. Prema Hamiltonu, **naftni su cjenovni šokovi osnovni uzrok gospodarskih recesija u SAD-u** do 80ih godina 20. stoljeća. Koristeći VAR model Hamilton je ustanovio postojanje jake negativne korelacije između rasta cijena nafte i stope realnog gospodarskog rasta SAD-a, kao i stope nezaposlenosti, ističući kako korelacija između cijena

nafte i ekonomskog rasta za razdoblje od 1948. do 1972. nije bila samo slučajnost. Godine *1986.*, *Gisser i Goodwin* ističu da u periodu od 1961. do 1982 g. cijene nafte i dalje imaju potencijal predviđanja stope rasta BDP-a. Oni, između ostalog, donose zanimljiv zaključak o međuovisnosti cijena nafte i makroekonomskih pokazatelja. Smatraju da poduzete mjere monetarne i fiskalne politike ne mogu u cijelosti objasniti efekte poskupljenja nafte na gospodarstvo. U skladu s tim zaključuju da naftni cjenovni šokovi osim proinflatornih pritisaka na gospodarstvo imaju i dodatan (negativan) utjecaj na razinu proizvodnje (u vidu smanjenja razine outputa).

Kasniji radovi, koji su obuhvatili duže vremenske nizove podataka (točnije, koji su za početak, uvrstili podatke iz 1980ih), ističu slabljenje veze između razine cijena nafte i makroekonomskih pokazatelja *(Lee et al., 1995; Hooker, 1996).* Kako je teško očekivati da tako važan energent nema stvaran utjecaj na gospodarstvo, znanstvenici su zaključili da je (u osamdesetim godinama prošlog stoljeća) očito došlo do **promjena u prirodi odnosa cijena nafte i BDP-a**, te spoznali da je problem u relacijama (metodologiji) kojima je do tada mjeren utjecaj cijena nafte na BDP. Primjerice, *Rotemberg i Woodford (1996*, str. 552.) tvrde da je jedan od mogućih razloga ovih promjena oslabljena moć OPEC-a u održavanju stabilnih nominalnih cijena nafte. Kao posljedica, snažne varijacije na strani potražnje za naftom brzo se pretaču u promjene nominalnih cijena nafte.

Pred znanstvenike je stavljen novi izazov u vidu potrage za relacijom koja će najbolje objasniti utjecaj cijena nafte na gospodarstvo, čak i kada se uključe noviji podaci (s većom volatilnošću cijena nafte). *Mork (1989)* među prvima sugerira postojanje asimetričnosti utjecaja cijena nafte na BDP, što do 1980ih i nije moglo biti zamijećeno budući da su se promjene cijena nafte sastojale isključivo od porasta cijena, pa su u takvim uvjetima i linearni modeli mogli ponuditi adekvatnu relaciju između kretanja cijena nafte i BDP-a. Mork pokazuje kako porast cijena nafte puno snažnije utječe na pad stope rasta BDP-a, negoli je to slučaj u obrnutoj situaciji (pada cijena nafte) kada gospodarstvo gotovo da ne reagira (reakcija bez značaja sa statističkog stajališta).

Lee et al. (1995) tvrde da više nije dovoljno korištenje klasične metodologije (promatranje promjene razine cijene nafte), već je neophodno metodološko uvažavanje volatilnosti cijena

nafte dajući pri tome važnost efektu iznenađenja[2]. Uključujući varijablu šoka promjene cijena nafte u svoj model (varijabla mjeri intenzitet promjene cijena nafte u tekućem u odnosu na prethodno razdoblje), autori dokazuju da je upravo efekt iznenađenja promjene cijena ključan u utjecaju na gospodarstvo. Ako niska volatilnost cijena na naftnim tržištima prethodi snažnom porastu cijena, utjecaj na gospodarstvo će biti puno snažniji, negoli da se rast cijena dogodio u uvjetima visoke volatilnosti.

Hooker (1996) također potvrđuje Hamiltonove rezultate i tvrdi da u razdoblju od 1948. do 1972. g. razina cijena nafte kao i njihova promjena imaju značajan utjecaj na rast BDP-a. No uzimajući u obzir podatke iz osamdesetih godina prošlog stoljeća (1973.-1994.), Hooker tvrdi da veza u potpunosti slabi, pri čemu čak ni Morkova specifikacija asimetrije ne nudi stabilnu relaciju utjecaja cijena nafte na BDP. No, uvažavanjem volatilnosti cijena nafte, Hooker ponovno dobiva stabilnu (negativnu) vezu između rasta cijena nafte i BDP-a, ističući da je irelevantna razina, ali je od ključnog značenja volatilnost cijena nafte.

Hamilton (1996) uvodi tzv. NOPI, pokazatelj koji eliminira utjecaj porasta cijene koji je u biti korektivan u odnosu na prethodno smanjenje razine cijena, jer se na taj način obuhvaća faktor iznenađenja koji se može tumačiti kroz makroekonomske šokove. Ovaj pokazatelj, čak i kad se uzmu u obzir kompletno dostupne vremenske nizove podataka, nudi stabilnu vezu između kretanja cijena nafte i BDP-a u SAD-u.

Kako je vidljivo iz novijih studija, volatilnost cijena nafte ima značajniji utjecaj na gospodarska kretanja od puke promjene razine cijena nafte. *Hamilton (2000)* pak ističe da **još uvijek ne postoji dovoljno povijesnog iskustva kako bi se mogla izolirati samo jedna najbolja relacija za pojašnjavanje utjecaja cijena nafte na gospodarstvo**. Sigurno je, pak, da su nelinearne relacije superiorne u odnosu na linearne kao i da promjene razine cijena nafte, u uvjetima visoke volatilnosti, imaju manju snagu predviđanja stope rasta BDP-a. Među novijim doprinosima na temu stabilnosti veze utjecaja cijena nafte na gospodarstvo (BDP) je *Hamiltonova studija (2001)* koja u linearni model uvodi nelinearne varijable (pokazatelje poput NOPI-a) i time nepobitno dokazuje stabilnost veze za cjelokupni promatrani vremenski period.

---

[2] Specifikacija efekta iznenađenja daje veliku važnost čak i manjim promjenama cijena ako one nastupe nakon dužeg perioda stabilnih cijena.

2010. godine *Rahman i Serletis* potvrđuju da (1983:M01 - 2008:M12) pored cijena nafte i volatilnost cijena nafte utječe negativno na makroekonomsku aktivnost SAD-a, u razdoblju od 1983. do 2008., pri čemu monetarna politika doprinosi asimetriji spomenutog utjecaja.

Među novijim utjecajnim radovima javljaju se i dokazi da **nije važan samo smjer i jačina naftnog šoka već i njegov uzrok**. Ispitujući utjecaj cijena nafte na uzorku SAD-a (koristeći VAR metodologiju), *Kilian (2009)* razlikuje tri temeljne vrste naftnih šokova, ovisno o njihovom uzroku. Naftne cjenovne šokove Kilian, kako je već spomenuto, dijeli na šokove na strani ponude, šokove na strani potražnje koji se javljaju kao posljedica gospodarske aktivnosti i šokove na strani potražnje koji su vođeni očekivanjima o budući cijenama nafte – špekulacijama. Dok šokovi na strani ponude, kao i šokovi na strani potražnje vođeni očekivanjima o budućim cijenama, imaju očekivan utjecaj na gospodarski rast, šok na strani potražnje vođen snažnom ekonomskom aktivnošću u kratkom roku povećava output (dok ga ostali šokovi smanjuju!). Ovaj zaključak je dijametralno suprotan onome što se do tada smatralo uobičajenim utjecajem rastućih cijena nafte na gospodarski rast. Literatura je mahom bila bazirana na ključnu pretpostavku da promjene cijena nafte proistječu iz egzogenih promjena u ponudi nafte. U novije je, pak vrijeme, opće prihvaćen stav da su cijene nafte i pod utjecajem potražnje, ne samo ponude (*cf. Barsky i Kilian, 2004; Hamilton, 2003*).

Sve navedene studije mahom su rađene na primjeru SAD-a. **Analize makroekonomskih učinaka cijena nafte na gospodarstvo izvan SAD-a značajno su zaostajale sve do posljednjeg desetljeća (od 2000. godine naovamo).**

Prva studija van SAD-a nakon one *Morka, Olsena i Mysena (1994)* je *Papapetrouova* studija iz *2001*. za Grčku, a nakon nje uslijedile su još dvije važne studije: *2003*. godine *Cuñado i Pérez de Gracia* analiziraju 14 europskih država, a iste godine *Miguel, Manzano i Martín-Moreno* analiziraju slučaj Španjolske. *Cuñado i Pérez de Gracia (2003)* pokazuju kako je efekt utjecaja cijena nafte veći kada se u obzir uzmu cijene nafte denominirane u nacionalnim valutama. Pretpostavlja se da je to posljedica utjecaja deviznih tečajeva. Funkcije impulsnog odziva (*engl. Impulse Response Functions - IRFs*) za 6 zemalja: Njemačku, Francusku, Luksemburg, Ujedinjeno Kraljevstvo, Nizozemsku i Dansku pokazuju **iznimne varijacije u jačini i značaju utjecaja cijena nafte, a ponekad i u smjeru utjecaja,** dok se sličnosti pronalaze ponajviše u *timingu*; negativni su efekti maksimalni oko 6 kvartala nakon naftnog šoka, a oporavak uslijedi

do najdalje 10 do 12 kvartala. Autori ističu kako nema dugoročne međuovisnosti između cijena energije i ekonomske aktivnosti, što implicira značaj utjecaja cijena nafte samo u kratkom roku.

Miguel et al. (2005) koriste model realnih poslovnih ciklusa (*engl. real business cycle*) za niz europskih zemalja (EU 15) u koji uvode egzogeno zadanu realnu cijenu nafte (zbog svoje uvozne ovisnosti o nafti), kao i kamatnu stopu jer se pretpostavlja da niti jedna od zemalja iz uzorka nije u mogućnosti utjecati na visinu cijena nafte. Također, promatra se isključivo utjecaj naftnih šokova, iako je poznato da oni nisu jedini izvor fluktuacija makroekonomskih pokazatelja. Autori tvrde kako je u jakim europskim gospodarstvima (Francuske, Ujedinjenog Kraljevstva, Nizozemske, Belgije, Luksemburga, Njemačke) monetarna politika odigrala važnu ulogu, posebno u naftnim šokovima sedamdesetih godina prošlog stoljeća, što za posljedicu ima manje oscilacije BDP-a u tim gospodarstvima u odnosu na ostale države iz uzorka, posebno: Portugal, Španjolsku, Grčku, i Italiju. Rezultati istraživanja **ističu ranjivost uvozno ovisnih ekonomija prilikom suočavanja s porastom cijena nafte,** što implicira važnost poznavanja njihovog utjecaja na gospodarstvo i njihovo uvažavanje prilikom analize poslovnih ciklusa u ekonomiji. Konačno, autori zaključuju kako su **naftni šokovi imali negativan utjecaj na standard stanovništva, posebno u južnoeuropskim zemljama (iz uzorka) čije su vlade na porast cijena nafte reagirale lošom poreznom politikom**.

Lardic i Mignon (2006) u svom istraživanju na 12 europskih gospodarstava za radoblje od 1970. do 2003., korištenjem testova za asimetričnu kointegraciju, zaključuju da realni gospodarski rast asimetrično reagira na cijene nafte (što nije dokazivo klasičnim testovima kointegracije). S druge strane, *Ran i Voon (2012)* na uzorku malih otvorenih azijskih zemalja (Hong Kong, Singapur, Južna Koreja i Tajvan; 1984Q1-2007Q3) zaključuju kako cijene nafte uopće ne utječu na realni BDP (iako uočavaju rast nezaposlenosti i inflacije).

Pri razmatranju mogućih uzroka negativne veze između porasta cijena nafte i gospodarskog rasta, literatura nudi niz mogućih odgovora. „Real balance“ efekt bio je među prvim objašnjenjima utjecaja naftnih šokova na agregatnu ekonomsku aktivnost gospodarstva *(Pierce i Enzler, 1974; Mork et al., 1994). Pierce i Enzler (1974)* tvrde da povećanje cijena nafte vodi porastu potražnje za novcem. Nemogućnost/nesposobnost monetarnih vlasti da poprate povećanu potražnju za novcem rastom njegove ponude, vodi povećanju kamatnih stopa, što smanjuje potrošnju i investicije i usporava gospodarski rast.

Jedno od mogućih pojašnjenja negativne veze cijena nafte i gospodarskog rasta je i objašnjenje putem klasičnog modela makroekonomskog šoka na strani ponude (*Rasche i Tatom, 1977; Brown i Yuckel, 1999).* Prema ovoj teoriji, porast cijena nafte signalizira oskudnost energenata koji su ujedno jedan od ključnih inputa u proizvodnji. Kao posljedica, rast proizvodnje i produktivnosti su usporeni. Smanjenje rasta produktivnosti smanjuje rast realnih plaća i povećava nezaposlenost pri čemu se povećava i stopa inflacije. Osnovna pretpostavka je da se nafta tretira kao intermedijarno dobro, no logično bi bilo učinak cijena nafte ograničiti u skladu s **udjelom troškova nafte u ukupnim troškovima u proizvodnji** koji su, što je poznato, relativno **mali**. U Hrvatskoj udio troškova nafte kao postotak BDP-a čini oko 5% (5,88% u 2007. i 4,35% u 2008; izračun autorice[3]), što je ekvivalentno svjetskoj praksi (u SAD-u 2009. je iznosio 4% BDP-a; *Hamilton, 2010).* **Unatoč tome, promjene cijena nafte rezultiraju snažnim oscilacijama realnog „outputa“**, što do tada ponuđeni modeli bazirani na strani ponude nisu bili u mogućnosti pojasniti (*Kilian, 2008a; Barsky i Kilian, 2004*). Evidentno je da niti modeli koji promatraju gospodarski rast kao funkciju i energije, a ne samo rada i kapitala, nisu zbog navedene restrikcije u mogućnosti razjasniti utjecaj cijena nafte na BDP (*Hamilton, 2010).*

H2: Promjene cijena nafte statistički značajno pozitivno utječu na kretanje inflacije.

Međunarodna kretanja cijena nafte iznimno su važna za razumijevanje kretanja opće razine cijena u gospodarstvu uzimajući u obzir udio potrošnje kućanstava na naftne derivate, kao i činjenicu da nafta predstavlja input u proizvodnji čitavog niza dobara i usluga. **Upravo se cijene energije mijenjaju puno češće od cijena ostalih dobara i usluga** *(Dhyne et al., 2006).* Nužno je razlikovati direktan i indirektan utjecaj cijena nafte na razinu ali i, što je važnije, na varijabilnost inflacije *(Álvarez et al., 2011).* Direktan utjecaj odražava se kroz gotovo trenutan porast cijena naftnih derivata, pri čemu će, naravno, snaga tog utjecaja ovisiti o zastupljenosti pojedinog derivata u ukupnoj potrošnji kućanstava. Indirektan se, pak, efekt očituje u promjenama troškova proizvodnje dobara i usluga kod kojih se naftni derivati koriste kao input

[3]**[** (**ukupna potrošnja nafte u barelima**, prema: US Energy Information Administration, International Energy Statistics) **x** (**prosječna cijena barela nafte u promatranoj godini**; prema: US Energy Information Administration, International Energy Statistics, Annual F.O.B. (Free on Board) Spot Price of Brent Crude Oil in Europe) **x** (**godišnji prosjek deviznog tečaja HRK/USD**; prema HNB Tečajna lista, Statistike tečaja)**]** / **(BDP u mil. kn u tekućim cijenama;** prema HNB, Statistika, Ekonomski indikatori) **x 100.**

u proizvodnji. Važna razlika između ovih dvaju utjecaja je i u njihovoj brzini, koja je znatno veća kod direktnog utjecaja.

Rastom cijena nafte raste i potražnja za novcem. Ako ponuda novca raste sporije od potražnje, dolazi do rasta kamatnih stopa što se negativno odražava na potrošnju i investicije, a samim time i gospodarski rast *(Pierce i Enzler, 1974)*. Kako se čini, monetarna politika može, do neke mjere, utjecati na način na koji će se efekt povećanja cijene nafte odraziti na pojedino gospodarstvo. Jedna od najcitiranijih studija na tu temu je i ona *Bernankea, Gertlera i Watsona* (1997, tzv. BGW studija). Autori studije tvrde kako restriktivna monetarna politika objašnjava glavninu smanjenja ekonomske aktivnosti koja uslijedi nakon porasta cijena nafte te da bi se negativni efekti mogli izbjeći uz trošak povišene stope inflacije. Za razliku od *Hamiltona (1983),* isti autori pripisuju gospodarske recesije koje su uslijedile nakon naftnih šokova upravo djelovanju monetarne politike.

Koristeći duže vremenske odmake (*engl. time lag*) od BGW na istim vremenskim nizovima podataka, *Hamilton i Herrera (2004)* dolaze do dijametralno suprotnih zaključaka. Oni tvrde da naftni šokovi imaju znatno jači direktan efekt na realnu ekonomiju sugerirajući da monetarna politika ima ograničen i gotovo neznatan utjecaj u ublažavanju realnih posljedica naftnih šokova. Dapače, oni smatraju da jednostavno nije moguće mjerama monetarne politike anulirati efekte naftnih šokova, te da bi porast inflacije koji sugeriraju BGW *(1997)* trebao biti previsok kako bi se ublažio efekt porasta cijena nafte.

Još je nekoliko studija potvrdilo ove zaključke. Između ostalog, *Davis i Haltiwagner (2001)* empirijski dokazuju da je efekt naftnih šokova na razinu zaposlenosti dvostruko jači od pukog utjecaja monetarne politike. Sukladno navedenom, nedvojbeno je da kanal monetarne politike nema snagu anuliranja (neutralizacije) ukupnih (negativnih) efekata naftnih šokova.

Balke, Brown i Yücel (2002) također su revidirali rezultate BGW studije, te u konačnici zaključuju da čak i kada se izolira utjecaj monetarne politike, i dalje postoji značajan utjecaj naftnih šokova na BDP, kao i asimetričan odgovor BDP-a i kamatnih stopa na promjene cijena nafte. Slijedom ovih zaključaka, autori istražuju i mehanizam kamatnih stopa kao mogući kanal transmisije efekata promjena cijena nafte na gospodarstvo, te zaključuju da se utjecaj naftnih šokova na ekonomiju rasprostire upravo posredstvom mehanizma kamatne stope. *Blanchard i Gali (2007)* tvrde kako se ponašanje monetarne politike promijenilo kroz vrijeme. U

sedamdesetim godinama prošlog stoljeća središnje banke nisu znale kako se ponašati u odnosu na naftne šokove, a i njihov je kredibilitet bio relativno nizak. U današnje vrijeme naftni šokovi više nisu novost, monetarna politika im se prilagođava, a i njen je kredibilitet značajno veći. Istražujući ulogu monetarne politike pri udaru naftnih šokova na američko gospodarstvo, *Leduc i Sill (2004)* zaključuju da su i output i inflacija manje volatilni kada se monetarna politika fokusira na stabilizaciju inflacije.

Peersman i Van Robays (2009) ističu kako su transmisijski mehanizmi u euro zoni značajno različiti u odnosu na one u SAD-u. Konkretno, proinflatorni pritisci u SAD-u prvotno su posljedica snažnog direktnog prelijevanja rasta cijena energije i rasta proizvodnih troškova pri čemu, primjerice, *Gao (2014)* tvrdi da najizraženiji pritisak na rast inflacije u SAD-u imaju upravo energija i energetski intenzivni proizvodi/usluge. U euro zoni inflacija, pak, reagira veoma sporo i u većoj je mjeri potaknuta drugom rundom efekata kroz porast nadnica. *Peersman i Van Robays (2009)* naglašavaju i poprilične razlike u reakcijama među članicama euro zone koje pripisuju razlikama u dinamici tržišta rada koje su dodatno potencirane zajedničkom monetarnom politikom koja ne odgovara na jednak način (u zadovoljavajućoj mjeri) svima.

Cuñado i Pérez de Gracia (2003) pokazuju kako je efekt utjecaja cijena nafte veći kada se u obzir uzmu cijene nafte denominirane u nacionalnim valutama. Pretpostavlja se da je to posljedica utjecaja deviznih tečajeva. U Hrvatskoj se, smatraju *Krtalić i Benazić (2008),* preferira kontrola deviznog tečaja (primarno zbog visoke uvozne ovisnosti i euroizacije). Sukladno tome, autori sugeriraju da se uslijed rasta cijena nafte inflatorni pritisci ublažavaju aprecijacijom deviznog tečaja. Kad je riječ o Hrvatskoj, *Payne (2002)* i *Malešević-Perović (2009)* ističu da na inflaciju pozitivno utječu plaće i deprecijacija valute. *Botrić i Cota (2006),* kao i *Vizek i Broz (2007)* također konstatiraju da je nominalni efektivni tečaj važna determinanta inflacije. Istraživanja upućuju na činjenicu da je u Hrvatskoj tečaj važna determinanta inflacije. Iz tog razloga je potrebno detaljno istražiti utjecaj cijena nafte na devizni tečaj koji posredno determinira i visinu inflacije.

Teorijski okvir nalaže da porast cijena nafte vodi smanjenju agregatne ponude, odnosno proizvodnje (zbog porasta troškova inputa). Kao posljedica rasta inflacije u zemlji, najvjerojatnije će rasti kamatna stopa kako bi se kontrolirao rast inflacije. Kao odgovor na povećanu kamatnu stopu, dolazi do priljeva stranog kapitala u zemlju, što vodi aprecijaciji

domaće valute (zbog povećane potražnje za domaćom valutom). Studije koje su to empirijski i dokazale su, primjerice, *Amano i van Norden (1998), Benassy-Quere et al. (2007), Huang i Guo (2007), Olomola i Adejumo (2006).*

Vizekova (2006) u svom istraživanju kanala monetarnog prijenosa također ističe da je monetarna politika Republike Hrvatske u tranzicijskom razdoblju značajno utjecala na realni sektor regulacijom novčane mase i deviznog tečaja (analogno situaciji kod zemalja srednje istočne Europe). Njeni rezultati potvrđuju da monetarna politika u Republici Hrvatskoj ne utječe na realnu ekonomsku aktivnost kroz kanal kamatne stope (slični zaključci i kod *Žigman i Lovrinčević, 2005)* dok se u EU 15 monetarni prijenos na realni sektor uglavnom odvija putem kamatnih stopa. To stavlja dodatnu težinu na provjeru postavljene hipoteze ističući neprimjenjivost sličnih istraživanja (uloge monetarne politike u načinu utjecaja cijena nafte na gospodarstvo) rađenih na razvijenim gospodarstvima EU. S obzirom da je struktura hrvatske privrede donekle slična strukturi gospodarstava srednje istočne Europe koja karakteriziraju: malo i otvoreno gospodarstvo, razvijen bankarski sustav, nerazvijeno financijsko tržište te prisutnost neslužbene euroizacije, rezultati empirijske analize *Vizekove* potvrđuju hipotezu da po pitanju aktivnosti kanala monetarnog prijenosa postoje velike sličnosti između Hrvatske i zemalja srednje istočne Europe.

U svom istraživanju o kanalima monetarne transmisije u Republici Hrvatskoj u periodu od 1998:M01 do 2009:M12, *Borozan (2011)* dolazi do sljedećih zaključaka: nominalni efektivni devizni tečaj je statistički najznačajniji kanal monetarne transmisije, dok je u dugom roku nominalna kamatna stopa najslabiji ali ipak statistički značajan kanal monetarne transmisije. U kasnijem radu, koristeći dulje vremenske nizove (period od 1998:M01 do 2012:M12) *Borozan i Sonora (2014)*, koncentriraju se na provjeru kanala deviznog tečaja i kamatne stope u transmisiji monetarnih šokova na ekonomiju. Monetarna kontrakcija popraćena je aprecijacijom efektivnog deviznog tečaja i, posljedično, slabljenjem ekonomske aktivnosti, pri čemu dolazi do rasta kamatne stope i inflacije. Autori ističu rastuću važnost kanala deviznog tečaja u pojašnjavanju varijacija u industrijskoj proizvodnji, ali i razinama cijena, kao i veoma slab kanal kamatne stope.

Hrvatsku karakterizira nedovoljno razvijeno financijsko tržište i visok stupanj euroizacije, što znatno utječe na smanjeni utjecaj monetarnih impulsa na realni sektor (*Žigman i Lovrinčević, 2005*). Stoga je primjenjivost rezultata usporedivih istraživanja u SAD-u i euro zoni (gdje je

efikasnost kanala kamatne stope primarni mehanizam monetarnog prijenosa) na Hrvatsku, u najmanju ruku, ograničena. Također, *Ivanov (2017, str. 18)* navodi svjetske cijene energenata kao izazov s kojim će se središnja banka susretati u narednim godinama prije uvođenja eura, a koji je u značajnoj mjeri izvan njene moći direktnog utjecaja. Pri tome autorica smatra da monetarne vlasti neće moći adekvatno reagirati zbog istodobne usmjerenosti na postizanje stabilnosti tečaja i konvergencije kratkoročnih kamatnih stopa.

Monetarna politika može, dakle, biti jedan od ključnih elemenata koji definiraju način na koji gospodarstvo amortizira naftni šok *(Pierce i Enzler, 1974; Bernanke, Gertler i Watson, 1997; Balke, Brown i Yücel, 2002; Hamilton i Herrera, 2004; Blanchard i Gali, 2007; Chen, 2009 i dr.).* Da bi se istražilo točno u kojoj mjeri monetarne vlasti koriste tu mogućnost, potrebno je prije svega definirati na koje transmisijske kanale monetarne politike realni sektor reagira.

Varijable za provjeru postavljene hipoteze odabrane su s ciljem identifikacije djelovanja pojedinih kanala monetarne transmisije uslijed pojave naftnih šokova. Kako nad kanalom novčane mase monetarne vlasti imaju direktan utjecaj, njegovo se uključenje u analizu nameće samo po sebi. Iako ranija istraživanja upućuju na priličnu neefikasnost djelovanja kanala kamatne stope, odabir provjere kanala kamatne stope, osim što je uobičajen kod reakcija monetarne politike na naftne šokove kod „zapadnih“ ekonomija, determiniran je i činjenicom da je upravo taj kanal jedan od najsnažnijih u zemljama EU-a (*Van Els et al., 2001; Peersman i Smets, 2001; Lovrinović i Benazić, 2004; Benazić, 2009*). Stoga je bitno dobiti nove ocjene njegove funkcionalnosti. Uz to se ispituje i, ranijim istraživanjima dokazano važan, kanal deviznog tečaja.

Pored prethodno istaknute važnosti provjere kanala deviznog tečaja, posebno u kontekstu hrvatskog gospodarstva, važno je istaknuti da je upravo devizni tečaj varijabla čiju važnost *Cologni i Manera (2005)* ističu tim više što je stupanj otvorenosti pojedine ekonomije veći. Iako navedena istraživanja, zbog korištenja tromjesečnih podataka, koriste pokazatelj BDP-a, ovdje će, zbog više frekvencije (mjesečne) vremenskog niza, biti korišten indeks industrijske proizvodnje kao proxy varijabla.

Uloga monetarne politike u mogućnosti određivanja jačine utjecaja naftnih šokova na gospodarstvo do danas je dvojbena. Što se tiče pojave asimetrije utjecaja naftnih cjenovnih šokova na gospodarski rast, autori istraživanja koja su je dokazali smatraju da monetarna

politika, ako i ima utjecaj na jačinu naftnog udara na gospodarstvo, nije jedini uzrok asimetriji, što traži daljnje istraživanje. Jedino u čemu se gotovo svi autori slažu je činjenica da **naftni šokovi**, u svakom slučaju, **povećavaju mogućnost grešaka u određivanju adekvatnih i pravodobnih mjera monetarne politike.** Kako ističe *Chen (2009),* iako ne postoji znanstveni konsenzus oko utjecaja cijena nafte na gospodarstvo posredstvom monetarne politike, može se reći da se cijene nafte barem djelomično prelijevaju (*engl. pass through*) u inflaciju. Zbog toga je monetarnim vlastima, koje je nastoje kontrolirati, u interesu što bolje razumjeti na koji način i koliko snažno cijene nafte utječu na inflaciju. Iz navedenih argumenata evidentna je važnost provjere postavljene hipoteze kako s aspekta znanstvenog doprinosa postojećim teorijskim saznanjima, tako i zbog praktične primjenjivosti trenutnim i budućim nositeljima monetarne politike (pogotovo za nove članice Europske monetarne unije; primjerice kako definirati ERM II razine deviznog tečaja[4]).

H3: Rast cijena nafte statistički značajno povećava nezaposlenost, dok pad cijena nafte nema statistički značajan utjecaj na nezaposlenost.

Stopa nezaposlenosti ovisi o nizu faktora; produktivnosti rada, nadnicama, cijenama (inflaciji), kao i ostalim proizvodnim inputima (primarno kapitalu). Ovome valja dodati i stanje u gospodarstvu (kao i njegovu strukturu), poslovne cikluse, stupanj razvoja tehnologije, demografske karakteristike radne snage, kao i globalne faktore poput cijena energije, odnosno nafte. Zbog socijalnih i ekonomskih konotacija, poznavanje svih faktora koji definiraju razinu (stopu) nezaposlenosti u dugom roku ključno je za nositelje politike.

Niz studija bavilo se pitanjem utjecaja cijena nafte na razinu (ne)zaposlenosti. Zbog otpornosti na smanjenje realnih plaća (tzv. rigidnosti nadnica), porast cijena nafte dovodi do zahtjeva za rastom nominalnih plaća. U kratkom roku, pritisak na plaće, zajedno sa smanjenom potražnjom, vodi većoj nezaposlenosti. Kako je i već ranije navedeno, jedno je moguće objašnjenje i putem klasičnog modela makroekonomskog šoka na strani ponude *(Rasche i Tatom, 1977; Brown i Yuckel, 1999),* prema kojem porast cijena nafte signalizira oskudnost energenata koji su ujedno

[4] Stabilan tečaj jedan je od preduvjeta koje država članica EU mora ispuniti sudjelovanjem u Europskome tečajnom mehanizmu (Exchange Rate Mechanism II - ERM II) neprekidno tijekom dvije godine. U tom razdoblju fluktuacije tečaja između eura i valute članice moraju se kretati u dogovorenim granicama od maksimalno ±15% od središnjeg pariteta. (Hrvatska Narodna Banka, http://old.hnb.hr/medjunarodna_suradnja/h-euro.htm, 12/2015)

jedan od ključnih inputa u proizvodnji. Kao posljedica, rast proizvodnje i produktivnosti su usporeni pri čemu smanjenje rasta produktivnosti smanjuje rast realnih plaća i povećava nezaposlenost.

Loungani (1986) ističe kako naftni šokovi vode realokaciji radne snage što povećava stopu nezaposlenosti. *Lee, Ni i Ratti (1995)* razmatraju sektorske realokacije kao moguće objašnjenje za izostanak statistički značajne promjene stope zaposlenosti prilikom pada cijena nafte. Hipoteza sektorske realokacije ističe kako uslijed porasta cijena nafte dolazi do transfera zaposlenih od energetski intenzivnih ka energetski efikasnim sektorima. Pri tome je brzina navedenih promjena veća uslijed rasta cijena nafte, negoli je to slučaj uslijed njihova pada. Kad cijene nafte padnu, sektorska realokacija radne snage ima negativne efekte na zaposlenost koji poništavaju pozitivne efekte makroekonomskog šoka (pozitivnog) na strani ponude. Isti autori uvode efekt iznenađenja u analizu, tvrdeći da neočekivanost promjene cijena nafte ima puno jači utjecaj na razinu zaposlenosti od same promjene cijena nafte.

Ferderer (1996) ističe kako agregatna nezaposlenost raste kada relativni cjenovni šokovi postanu volatilniji, što implicira da volatilnost cijena nafte osnažuje poremećaje u sektorskim prilagodbama na tržištu rada, vodeći većoj nezaposlenosti. *Keane i Prasad (1996)* u svom istraživanju utjecaja na zaposlenost zaključuju kako porast cijena nafte u prosjeku smanjuje realne plaće svih zaposlenih, ali povećava relativne plaće obučenijih radnika (*engl. skilled workers*). Mogućnost zapošljavanja obučenijih radnika raste usporedno s rastom cijena nafte sugerirajući da je vješt radnik adekvatan supstitut za poskupjeli energent. Također, konstatiraju da je u kratkom roku efekt porasta cijena nafte na zaposlenost negativan, dok je u dugom roku pozitivan, kao posljedica supstitucije proizvodnih inputa.

Davis i Haltiwanger (2001) su uz pomoć VAR modela istražili reakciju kreiranja i destrukcije radnih mjesta (*engl. job creation and destruction*), ovisno o tome je li došlo do pada ili rasta cijena nafte. Zaključak studije je da stopa rasta nezaposlenosti asimetrično reagira na promjene cijena nafte. Autori smatraju kako zaposlenost reagira negativno na porast cijena nafte jer u toj situaciji agregatni i alokativni mehanizmi djeluju u istom smjeru, dok u situaciji pada cijena nafte spomenuti mehanizmi djeluju u suprotnim smjerovima anulirajući moguće pozitivne efekte na razinu zaposlenosti. *Carruth, Hooker i Oswald (1998)* istražili su utjecaj cijena nafte na zaposlenost koristeći tzv. model korekcije pogreške. Njihovi rezultati također upućuju na

inverzan odnos između porasta cijena nafte i zaposlenosti, iako se autori u ovom slučaju ne slažu s tezom sektorske realokacije radne snage.

Zanimljivo bi bilo spomenuti i utjecaj cijena nafte na strukturu potražnje, mehanizam koji se u konačnici očituje u razini zaposlenosti, ali mu utjecaj kreće kroz poremećaje sektorski specifične potražnje *(Jones, Leiby i Paik, 2004).* Potražnja za trajnim dobrima (ponajviše automobilima) posebice je pogođena u vremenima recesija jer potrošači (zbog oslabljene kupovne moći) preusmjeravaju potražnju na potrošna dobra (hranu, odjeću, obuću). Na taj način stradavaju sektori, odnosno industrije koje proizvode trajna dobra, što u konačnici znači otpuštanje radne snage u tim sektorima. Najbolji primjer je situacija u autoindustriji koja je uvijek snažno pogođena jakim naftnim šokovima.

Zajednički nazivnik navedenim studijama je svakako uzorak, uzorak razvijenih zemalja, uglavnom je riječ o SAD-u. Literatura o utjecaju cijena nafte na ne/zaposlenost u ostalim je zemljama izrazito skromna. Može se istaknuti studija *Papapetroua (2001)* na primjeru Grčke koja ukazuje na negativan trenutan utjecaj cijena nafte na zaposlenost. Osim toga, autor ističe kako cijene nafte imaju značajnu ulogu u pojašnjavanju fluktuacija realnih stope rasta kao i rasta stope nezaposlenosti. *Robalo i Salvado (2008)* na primjeru Portugala pokazuju sličnost s rezultatima industrijaliziranih zemalja; značajan utjecaj cijena nafte na nezaposlenost koji slabi nakon 1986. Pored navedenih, studija *Doğrula i Soytasa (2010)* istražuje, i na primjeru Turske dokazuje, vezu između cijena nafte, nezaposlenosti i kamatne stope, pri čemu se, suprotno očekivanom, nezaposlenost smanjuje kao odgovor na naftni cjenovni šok. *Van Wijnbergen (1985)* tvrdi da je naftni šok 1974. godine producirao različite reakcije u razvijenim i u manje razvijenim zemljama implicirajući razlike u dinamičkim relacijama između cijena nafte i stopa nezaposlenosti. Navedeno stavlja dodatnu težinu na provjeru odnosa navedenih varijabli na razini pojedinog gospodarstva.

Autori navedenih studija nisu uspjeli nepobitno potvrditi hipotezu o sektorskoj realokaciji radne snage, no samo je jedna od navedenih studija koristila pokazatelj promjene cijena nafte koji uvažava asimetriju utjecaja na gospodarstvo (Dawis i Haltiwagnerova studija). Stoga će elaborirana hipoteza ispitati utjecaj cijena nafte na nezaposlenost uvažavajući asimetriju.

H4: Promjene cijena nafte statistički značajno negativno utječu na kretanje osobne potrošnje.

Mehanizam utjecaja cijena nafte na potrošnju može se promatrati izravno i neizravno. Realni rast podrazumijeva i rast potražnje za dobrima i uslugama odnosno, posredno, i rast potražnje za energijom i to na dva ključna načina. S jedne je strane energija ključan proizvodni input, a s duge je nužna u sektoru transporta koji je ključna karika u distribuciji, ali i nezaobilazan preduvjet potrošnji široke palete proizvoda i usluga. *Bhattacharyya (2011)* nudi detaljan opis ovog utjecaja ističući da rast cijena nafte općenito povećava troškove potrošnje čime opada količina potražnje za svim dobrima i uslugama. Neposredan utjecaj rasta troškova transporta na smanjenje potrošnje proizlazi iz potrebe čovjeka za kretanjem, bilo da se radi o dnevnim migracijama na radno mjesto i natrag, ili povremenim putovanjima u različite svrhe; bilo da je riječ o osobnom automobilu, autobusu ili zrakoplovu.

Pored očitog izravnog (i najbržeg) utjecaja najzastupljenijeg energenta, nafte, na transportne troškove (bilo potrošača, bilo dobara i usluga koje konzumiraju) postoje i drugi, ne tako očiti, mehanizmi mogućeg utjecaja cijena nafte na potrošnju. Ranije je pojašnjen mehanizam utjecaja cijena nafte na inflaciju: rast cijena nafte dovodi do rasta proizvodnih troškova (rasta cijena pri proizvođačima) koji se uglavnom prevaljuje na krajnje kupce, što dovodi do rasta cijena svih dobara i usluga, odnosno rasta opće razine cijena - inflacije (*Bernanke et al., 1997*). Ako rast nominalnih plaća ne prati rast inflacije, realni se dohodak smanjuje, a posljedično i potrošnja (efekt dohotka). Uloga monetarne politike u ovom je procesu također iznimno važna; monetarne vlasti koje često ciljaju niske stope inflacije (*engl. inflation targeting*) mogu restriktivnim mjerama još u većoj mjeri (od samog rasta cijena nafte) smanjiti realne stope rasta gospodarstva, a posljedično čak i povećati stopu nezaposlenosti (za ove je procese, svakako, potrebno nešto više vremena). Također, efekt supstitucije u izravnoj potrošnji naftnih derivata je izraženiji u dugom roku (i pozitivno korelira s rastom cijena nafte), a osim o vremenu prilagodbe na promjenu cijena ovisi i o mogućnostima supstitucije nafte drugim energentima.

Hamilton (2008) navodi kako je ključni mehanizam utjecaja cijena nafte na gospodarstvo upravo na strani potražnje, gdje naftni cjenovni šok uzrokuje poremećaj u potrošnji i kućanstava i poduzeća čak i ostalih dobara izuzev same nafte/tekućih goriva. *Lee i Ni (2002)* ističu kako tvrtke u SAD-u ne percipiraju naftne šokove kao udar na troškove proizvodnje, već kao udar na

potražnju za njihovim proizvodima. S druge pak strane, *Bohi (1991)* navodi da nema dokaza kako industrije s značajnijim udjelom energije trpe znatnije posljedice naftnih šokova od industrija kod kojih je taj udio niži.

Povećanje cijena nafte ostavlja manje sredstava za potrošnju na ostala dobra. Iako je prisutan izražen fokus medija i politike na ovu tematiku, još uvijek se malo zna o jačini ovog efekta, o utjecaju na realnu potrošnju, kao i samim promjenama u potrošnji koje se javljaju kao odgovor na fluktuacije u cijenama nafte *(Edelstein i Kilian, 2009).* Koliko će sam efekt porasta cijena nafte biti jak, ovisi o elastičnosti potražnje; što je elastičnost manja, efekt je snažniji, i obratno. Kako rastu cijene nafte, kućanstva odgađaju ili se u potpunosti suzdržavaju od kupnje trajnih dobara *(Bernanke, 1983; Pindyck, 1991),* posebno onih čije funkcioniranje zahtijeva uporabu energije/nafte (iz tog razloga u ovu skupinu ponajprije spadaju automobili; *Hamilton, 1988).* Pad potražnje za dobrima moguće je i posljedica porasta sklonosti štednji kao mjere predostrožnosti uslijed promjenjivosti cijena i rezultirajuće neizvjesnosti *(Kilian, 2008a).*

Valja uzeti u obzir i indirektne efekte povezane s promjenama ponašanja potrošača. Dio literature ističe kako promjene uzoraka potrošnje pod utjecajem povećane neizvjesnosti uzrokuju alokativne poremećaje koji rezultiraju sektorskim pomacima od energetski intenzivnih ka energetski efikasnim sektorima *(Davis, 1987; Hamilton, 2008).* Slične se realokacije mogu dogoditi i unutar samog sektora ako kupci preferiraju energetski efikasnije proizvode *(Hamilton, 1988; Bresnahan i Ramey, 1993).* Indirektni efekti mogli bi biti čak i veći od već nabrojenih direktnih, kako ističu *Davis i Haltiwanger (2001)* te *Lee i Ni (2002)*, ali zahtijevaju više vremena od direktnih efekata.

Istraživanja koja ispituju utjecaj cijena nafte na potrošnju (kućanstva i osobnu potrošnju općenito) iznimno su rijetka, što donekle čudi s obzirom na važan utjecaj potrošnje na realni gospodarski rast. Od novijih se istraživanja mogu istaknuti *Mehra i Petersen (2005), Edelstein i Kilian (2009), Odusami (2010), Wang (2013) i Zhang et al. (2014). Mehra i Petersen (2005)* zaključuju da je veza između cijena nafte i potrošnje asimetrična i nelinearna, pri čemu rast cijena nafte ima negativan efekt na potrošnju, a pozitivan utjecaj na potrošnju u slučaju pada cijena nafte nema. Autori također navode da rast cijena nafte značajnije utječe na pad potrošnje kada je neočekivan, odnosno kada uslijedi nakon dužeg perioda stabilnih cijena. *Odusami (2010)* dolazi do vrlo sličnih zaključaka. *Edelstein i Kilian (2009)* ne nalaze dokaze asimetrije, ali se slažu s *Mehra i Petersen (2005)* da cijene nafte statistički značajno utječu na potrošnju.

Osim navedenih istraživanja za SAD, *Wang (2013)* uočava različite reakcije gospodarstva unutar grupacije G7, a *Zhang (2014)* oprečne rezultate za Kinu. *Zhang i Broadstock (2014)* također ističu različite reakcije potrošnje na cijene nafte u zemljama ASEAN-a i istočne Azije. Evidentno, ni po pitanju utjecaja cijena nafte na potrošnju ne postoji znanstveni konsenzus.

H5: Promjene cijena nafte statistički značajno utječu na kretanje investicija.

Investicije predstavljaju ključnu komponentu agregatne potražnje zbog doprinosa rastu kapitala što, prema modelima ekonomskog rasta, vodi gospodarskom rastu i prosperitetu *(Mankiw, 2006).* Investicije (posebno one koje podrazumijevaju širenje poslovanja) doprinose rastu potražnje i potrošnje i stope zaposlenosti, a osim toga, rast investicija je i indikator pozitivnih očekivanja investitora glede budućih gospodarskih kretanja.

Važnost cijena nafte u kontekstu investicija posljedica je njihovog utjecaja na neizvjesnost poslovnog okruženja unutar kojeg se donose investicijske odluke. Neizvjesnost ne definira samo vrijednost pojedine investicije, već i vrijednost tvrtke koja ju poduzima *(Miller, 1998),* a upravo su se cijene nafte istaknule kao važan faktor u doprinosu neizvjesnom poslovnom okruženju s potencijalom još značajnijeg utjecaja u budućnosti *(Henriques i Sadorsky, 2011).* Iako se nafta najčešće promatra kao (važan) input u proizvodnji, čak i one tvrtke koje ne koriste direktno naftu u poslovnom procesu koriste njene derivate, te se smatra da oko 98% svih dobara koje konzumiraju krajnji potrošači dolazi u doticaj s naftom u pojedinom segmentu vrijednosnog lanca *(Henriques i Sadorsky, 2011).*

Unatoč akademskom konsenzusu oko nedvojbene važnosti investicija u gospodarstvu, razumijevanje determinanti investicija (pa i empirijski dokazi istih) na makroekonomskoj i mikroekonomskoj razini u najmanju je ruku ograničeno. Štoviše, ovo je jedan od slabije istraženih segmenata u ekonomiji; osim što predloženi modeli nisu adekvatno pojašnjavali kretanje investicija, proporcije varijacija varijabli koje se tradicionalno smatraju odgovornima za kretanje (varijacije) razine investicija, poput troška kapitala, u stvarnosti su nedovoljne kako bi se pojasnile varijacije investicija (*Dixit i Pindyk, 1994; Chirinko, 1993*). Ovome značajno pridonosi i činjenica da su razlike u zastupljenosti investicija u gospodarstvu među različitim ekonomijama izrazito velike, što u novije vrijeme potiče znanstvenike na provjeru hipoteza o

utjecaju, primjerice, institucionalnih čimbenika na investicije (u odnosu na klasične; kamatnu stopu, realni devizni tečaj te mjere monetarne i fiskalne politike) *(Lim, 2013).*
Rast cijena nafte čini naftu manje poželjnim proizvodnim inputom u odnosu na ostale oblike energije, kao i u odnosu na kapital i/ili rad pri čemu stupanj supstitucije ovisi o tehničkim mogućnostima ali i o trošku supstitucije. Upravo je procjena troška, odnosno isplativosti, supstitucije nafte ostalim proizvodnim inputima najveći izazov (i jako nezahvalan posao) jer podrazumijeva poznavanje budućih kretanja cijena nafte, odnosno troška/cijene ostalih proizvodnih inputa. *Broadstock et al.* (*2007, str. 48;* u svom pregledu 375 različitih istraživanja o mogućnosti supstitucije proizvodnih inputa) ističu da se energija i kapital generalno ponašaju kao komplementi ili slabi supstituti. Ako su nafta i kapital blagi supstituti, smanjenje korištenja nafte bi zahtijevalo značajan rast udjela kapitala u proizvodnom procesu kako bi se održala ista razina proizvodnje. Ako su pak energija i kapital komplementi, tada bi rast cijena nafte trebao rezultirati smanjenjem korištenja i energije/nafte i kapitala, povećavajući na taj način utjecaj rasta cijena nafte na gospodarstvo.

Analizirajući podatke nefinancijskih tvrtki u 15 europskih zemalja (i 25 različitih industrija) u periodu od 1991 do 2006, *Ratti et al. (2011)* su utvrdili da u 14 od 15 zemalja relativne cijene energije negativno utječu na investicije na razini tvrtke.

Ferderer (1996), pak, razmatra nesigurnost/neizvjesnost glede budućih cijena nafte, tvrdeći da porast cijena nafte utječe na gospodarstvo i kroz smanjenje investicija (ovu su tvrdnju kasnije potvđivala i druga istraživanja, *cf. Wang et al., 2017*). *Bernanke (1983)* pojašnjava kako tvrtke zbog neizvjesnosti o budućim kretanjima cijena nafte nastoje odgoditi planirane investicije. Kako se nesigurnost glede budućih cijena nafte povećava, raste vrijednost odgođenih, do tada planiranih investicija, dok motivacija za daljnjim investicijama opada. Ova neizvjesnost ima implikacije i na strani ponude i na strani potražnje; neizvjesnost proizlazi iz očekivanja o budućim cijenama nafte, dakle troškovima inputa, odnosno, iz očekivanja o budućim prihodima, odnosno promjenama u potražnji za njihovim outputom. Dolazeći do vrlo sličnih rezultata, *Yoon i Ratti (2011)* ističu i kako je negativan utjecaj neizvjesnosti na investicije prisutan neovisno o energetskoj intenzivnosti pojedine industrije.

Ovome valja dodati i da neizvjesnost glede budućih cijena raste neovisno o tome radi li se o rastu ili padu cijena nafte. Dakle, neizvjesnost je pozitivno korelirana s volatilnošću cijena nafte *(Elder i Serletis; 2009, Elder i Serletis; 2010*).

Unatoč postojanju pojedinih studija utjecaja cijena nafte na investicije (*Ferderer, 1996; Bernanke, 1983),* zanimljivo je istaknuti da još uvijek nema empirijskih dokaza o asimetričnom utjecaju cijena nafte na investicijsku potrošnju *(Kilian, 2008a)*, što stavlja dodatnu težinu na provjeru postavljene hipoteze koja u pojedine pokazatelje cijena nafte ima ugrađenu upravo pretpostavku o asimetriji. Iznimno je važno također istaknuti da su malobrojna istraživanja utjecaja cijena nafte na investicijsku potrošnju vršena na razini poduzeća, dakle mikro razini, što ovdje neće biti slučaj. Istraživanja utjecaja cijena nafte na investicije na agregatnoj (makro) razini izuzetno su rijetka.

H6: Cijene naftnih derivata asimetrično reagiraju na promjenu cijene nafte.

Niz utjecajnih istraživanja ponudilo je zaključak o asimetričnom utjecaju cijena nafte na gospodarstvo (*Mork, 1989; Mork et al., 1989; Lee et al., 1995; Ferderer, 1996; Hamilton, 1996, 2003; Davis i Haltiwagner, 2001*). Ipak, svega nekolicina njih pokušala je istražiti izvorište ovakve prirode utjecaja cijena nafte na gospodarstvo. Jedno od mogućih pojašnjenja asimetričnog utjecaja cijena nafte na gospodarstvo je asimetrija u reakciji cijena naftnih derivata na promjenu cijena nafte koja podrazumijeva bržu i/ili potpuniju prilagodbu cijena naftnih derivata cijenama nafte u slučaja njihova rasta, nego li je to slučaj u slučaju njihova pada (kada je prilagodba cijena naftnih derivata sporija i/ili nepotpuna) (*Huntington, 1998*). Da bi se istražilo eventualno postojanje cjenovne asimetrije, odnosno ispitao način na koji cijene naftnih derivata u Hrvatskoj reagiraju na promjene cijena sirove nafte, postavljena je hipoteza H6.

Upravo postojanje cjenovne asimetrije utjecaja cijena nafte na naftne derivate može biti eventualno pojašnjenje asimetričnog utjecaja cijena nafte na gospodarstvo *Huntington (1998)*, ako se isti dokaže.

1.4. METODE ISTRAŽIVANJA

Kako bi se testirale navedene hipoteze i u konačnici postigli prethodno istaknuti ciljevi istraživanja, bit će korišten niz znanstveno-istraživačkih metoda u svrhu eksplikacije, elaboracije i empirijske verifikacije postavljenih hipoteza. Istraživanje se može razložiti na teorijski i empirijski dio, što će se očitovati korištenjem specifičnih znanstveno-istraživačkih metoda u svakom od navedenih dijelova.

Temelj za izradu i elaboraciju **teorijskog dijela** disertacije predstavlja prikupljanje i proučavanje relevantne literarne građe vezane uz problematiku doktorske disertacije; knjiga, znanstvenih i stručnih članaka, studija, izvješća, zakona i publikacija dostupnih na internetskim stranicama. Prilikom izrade **teorijskog dijela** disertacije bit će korišten niz utemeljenih znanstveno-istraživačkih metoda (prema *Zelenika, 2000*, *str. 295-311*);

- *metoda kompilacije* za preuzimanje te predstavljanje postojećih znanstveno-istraživačkih spoznaja,
- *metoda klasifikacije* za sistematizaciju poznatih istraživanja kanala utjecaja cijena nafte na gospodarstvo,
- *metoda analize* kojom će se raščlanjivanjem već poznatih tvrdnji steći jasnija predodžba o predmetu proučavanja da bi se *metodom sinteze* povezale jednostavne tvrdnje i zaključci u složnije i općenitije tvrdnje i zaključke, primjenjive na predmetno istraživanje,
- *metoda apstrakcije i konkretizacije*, čijim će se primjenama elementi predmeta istraživanja razložiti na bitne i nebitne,
- *metoda generalizacije*, putem koje će se uopćiti pojmovi u zaključke koji će biti primjenjivi na predmetno istraživanje,
- *metoda dokazivanja i opovrgavanja,* kako bi se izvršila primjerena interpretacija ekonometrijskih rezultata postavljenih istraživačkih hipoteza,
- *metoda deskripcije* u svrhu opisivanja znanstvenih činjenica,
- *komparativna metoda* za usporedbu rezultata različitih istraživanja slične problematike te
- *induktivna i deduktivna metoda*, za donošenje zaključaka.

Empirijski dio disertacije zahtijeva korištenje različitih statističkih i matematičkih metoda s naglaskom na ekonometrijsko modeliranje. Kroz teorijski dio istraživanja formulirane su pretpostavke o vezama i međuovisnostima promatranih varijabli, dok će se metodama matematičke ekonomije teorijski zasnovane pretpostavke preformulirati u ekonomske, odnosno, ekonometrijske modele temeljem kojih će biti testirana (ponuđenim hipotezama uobličena) ekonomska teorija. Pri istraživanju su korišteni sekundarni podaci, točnije, vremenski nizovi realnih ekonomskih podataka (hrvatskog gospodarstva) prilagođeni metodama ekonometrijske analize. Konkretizacija podataka, koji će biti podvrgnuti testiranju, zahtijeva uporabu metode uzorka, pri čemu će se podaci (gdje je to moguće) grafički prikazivati u svrhu jasnije predodžbe.

U istraživanju će se, sukladno praksi kod ovakvog tipa istraživanja, koristiti vektorski autoregresijski modeli (VAR) i vektorski modeli korekcije pogreški (VECM – *engl. Vector Error Correction Model*), odnosno modeli korekcije pogreški (*ECM – engl. Error Correction Model*) ako je riječ o bivarijantnom okruženju (kod provjere hipoteze H6). U sklopu poglavlja 4. (odjeljaka 4.1. i 4.2.) detaljno su obrazložene korištene ekonometrijske metode i modeli.

1.5. OČEKIVANI ZNANSTVENI DOPRINOS

Provedba istraživanja kojim bi se testirale postavljene hipoteze, odnosno izrada same disertacije na predloženu temu, trebala bi, sukladno prethodno navedenim ciljevima, rezultirati značajnim doprinosom na različitim nivoima.

Predložena je tema aktualna, u hrvatskoj literaturi iznimno zapostavljena, a u stranoj nedovoljno obrađena; stoga bi se **znanstveni doprinos** predloženog istraživanja trebao očitovati kroz:

- doprinos razvoju znanstvenih spoznaja o formiranju cijena nafte kroz eksplikaciju i teorijsku sistematizaciju varijabli pod čijim utjecajem dolazi do samih promjena cijena nafte,
- klasifikaciju i sistematizaciji koncepata i smjerova istraživanja utjecaja cijena nafte na gospodarstvo,
- doprinos razvoju znanstvenih spoznaja o utjecaju cijena nafte na odabrane makroekonomske pokazatelje,
- oblikovanje konceptualnog modela za utvrđivanje zakonitosti, smjera i intenziteta veze između cijena nafte i odabranih makroekonomskih pokazatelja, imajući u vidu cjelovitiji sustav promatranih međuodnosa varijabli, kao i pojedinačan utjecaj na svaki promatrani makroekonomski pokazatelje, te
- ukazivanje na ograničenja pri provođenju ovakvog tipa istraživanja s implikacijama za moguća daljnja istraživanja u ovom području.

Aplikativni doprinos istraživanja proizići će iz:

- provedenih ekonometrijskih analiza utjecaja cijena nafte na odabrane makroekonomske pokazatelje u RH, primarno BDP, inflaciju, nezaposlenost, potrošnju i investicije,
- komparacije s iskustvima razvijenih zemalja, ukazivanja na specifičnosti utjecaja cijena nafte na hrvatsko gospodarstvo s potencijalnom primjenom na post-tranzicijska gospodarstva u razvoju općenito,

- identifikacije najprikladnijeg pokazatelja cijene nafte koji će ujedno pobliže definirati i prirodu utjecaja cijena nafte na hrvatsko gospodarstvo, te
- sistematizacije rezultata o utjecaju cijene nafte na bruto domaći proizvod, inflaciju, nezaposlenost, potrošnju i investicije, kao podloge ekonomskim autoritetima za jednostavnije razumijevanje mehanizama utjecaja cijena nafte na hrvatsko gospodarstvo i, posljedično, donošenje primjerenih ekonomskih odluka.

Kako je ranije istaknuto, **dosada poznata istraživanja rađena su mahom na razvijenim zemljama različitih razvojnih i strukturnih karakteristika** u odnosu na Republiku Hrvatsku. Stoga bi ovo istraživanje imalo značajne implikacije za post-tranzicijska uvozno ovisna gospodarstva u razvoju općenito jer **su ekstenzivna istraživanja na grupaciji tih zemalja iznimno oskudna**. Rezultati (kao i korištene ekonometrijske metode, točnije modeli) mogli bi se preslikati i na ostala post-tranzicijska gospodarstva (ovisna o uvozu nafte) općenito. Postojeća rasprava o utjecaju cijena nafte na hrvatski ekonomski rast još uvijek nije ni približno dosegnula adekvatnu razinu znanstveno-stručne argumentacije. Iako se u svjetskoj znanstvenoj literaturi sve više razmatra utjecaj cijena nafte na gospodarski rast, spomenuta problematika u Hrvatskoj oskudijeva teorijskom i empirijskom potporom što, u kontekstu visoke uvozne ovisnosti o nafti, može lako dovesti do donošenja i/ili provođenja neadekvatne politike. Navedeno je ključni motiv da se cjelovitije sagleda te sustavnije analizira utjecaj cijena nafte na gospodarstvo u cjelini.

1.6. STRUKTURA RADA

Rezultati istraživanja u okviru ove doktorske disertacije sustavno su iznijeti kroz pet poglavlja.

U uvodnom dijelu rada elaborirani su problem i predmet istraživanja u širem kontekstu s ponuđenom elaboracijom temeljnih prethodno provedenih istraživanja kao i neodgovorene istraživačke dileme područja istraživanja. Slijedom istražene problematike postavljeni su ciljevi istraživanja te klasificirani na znanstvene i aplikativne u skladu s kojima se, u nastavku, nude formulacije istraživačkih hipoteza, temeljene na postojećoj literaturi i dosadašnjim teorijskim spoznajama. U nastavku poglavlja navedene su i istraživačke metode korištene u istraživanju, kao i očekivani znanstveni doprinosi, a završno i opis strukture doktorske disertacije.

Drugi dio, pod naslovom **Makroekonomski učinci kretanja cijena nafte**, obuhvaća tri potpoglavlja kroz koja se detaljno pojašnjava redom; međuodnos energije i gospodarskog rasta, mehanizmi utjecaja cijena nafte na gospodarstvo, a potom i determinante kretanja cijena nafte, odnosno ključne karakteristike svjetskog naftnog tržišta s osvrtom na povijesno kretanje cijena nafte. Kako je pitanje gospodarskog rasta centralno makroekonomsko pitanje, prvi dio poglavlja nudi pojašnjenje veze energije i gospodarskog rasta. Drugi dio poglavlja posvećen je elaboraciji mehanizama utjecaja cijena nafte na gospodarstvo kroz pregled dosadašnjih istraživanja o utjecaju cijena nafte na pojedine makroekonomske pokazatelje. Konačno, kako je nafta i dalje najzastupljeniji svjetski energent, posljednji dio poglavlja obrazlaže determinante koje, prema postojećim teorijskim saznanjima, oblikuju njenu cijenu i nudi povijesni pregled kretanja cijena nafte s elaboracijom uzroka dosadašnjih naftnih šokova.

Imajući u vidu činjenicu da se predloženo istraživanje fokusira na hrvatsko gospodarstvo, pa je, shodno tome, nužno uzeti u obzir njegove specifičnosti, u trećem poglavlju, pod istoimenim naslovom, dana je **Analiza makroekonomskih pokazatelja hrvatskog gospodarstva**, što predstavlja svojevrsnu pripremu za empirijski dio istraživanja. Vodeći se odabranim uzorkom i vremenskim periodom analize, od 1995. do 2015. godine (što je posljedica dostupnosti podataka za ekonometrijsku analizu), kroz poglavlje se analizira kretanje ključnih makroekonomskih pokazatelja: bruto domaćeg proizvoda, inflacije, nezaposlenosti, osobne potrošnje i investicija, čija se reakcija u odnosu na promjene cijena nafte analizira u narednom poglavlju disertacije. S obzirom na činjenicu da se tek manji dio nafte troši u nerafiniranom obliku, te da je potražnja za istom u stvarnosti izvedena iz potražnja za njenim derivatima, poglavlje na koncu nudi i analizu hrvatskog tržišta naftnih derivata, načina formiranja krajnjih cijena naftnih derivata u Hrvatskoj kao i njihovu usporedbu na razini EU i u odnosu na SAD.

Četvrti dio, pod naslovom **Istraživanje utjecaja cijena nafte na makroekonomske pokazatelje hrvatskog gospodarstva**, predstavlja srž istraživanja. U prvom dijelu poglavlja ponuđen je konceptualni model istraživanja kao i detaljan pregled korištene metodologije i podataka istraživanja. Među ostalim, detaljno su elaborirana i četiri različita pokazatelja cijena nafte čijom se permutacijom u empirijskoj fazi testiraju postavljene istraživačke hipoteze. U nastavku poglavlja predočeni su rezultati ekonometrijskog istraživanja utjecaja cijena nafte na bruto domaći proizvod, inflaciju, nezaposlenost, osobnu potrošnju, investicije i naftne derivate u RH. Nakon empirijske verifikacije hipoteza detaljno su interpretirani rezultati istraživanja, a potom je ponuđena i rasprava o istima imajući u vidu prethodno postavljene ciljeve, kao i

postojeće teorijske i empirijske spoznaje usporedivih istraživanja. Na koncu poglavlja, navedena su i realna ograničenja provedenog istraživanja kao i implikacije za buduća istraživanja.

Kroz posljednje poglavlje, **Zaključak**, ponuđen je osvrt na cjelokupno istraživanje kroz ključne konstatacije koje se mogu izvući temeljem proučavanja i sistematizacije postojećih teorijskih i empirijskih spoznaja, kao i provedenog ekonometrijskog testiranja predloženih istraživačkih hipoteza. Konačno, navedena su i zaključna razmatranja o istraživačkom problemu u širem kontekstu istraživanja.

2. MAKROEKONOMSKI UČINCI KRETANJA CIJENA NAFTE

U ovom su poglavlju dane teorijske postavke kao i pregled postojećih istraživanja o makroekonomskim učincima kretanja cijena nafte. Iako je nafta najzastupljeniji energent današnjice (što će u nastavku poglavlja biti i argumentirano), ipak je samo jedan od energenata koje čovječanstvo koristi. Stoga je nužno utjecaj energije na realni rast promatrati u širem kontekstu. Ovo podrazumijeva isticanje uloge, odnosno utjecaja, energije na gospodarski rast, bilo da je riječ o ulozi energije (pa samim time i nafte) u ekonomskim teorijama rasta ili pregledu postojećih empirijskih istraživanja o odnosu potrošnje energije i gospodarskog rasta. U nastavku poglavlja naznačene su ključne karakteristike svjetskog naftnog tržišta kako bi se mogao steći uvid u kompleksne međuodnose koji globalno utječu na definiranje cijena nafte, kao i pregled kretanja globalnih cijena nafte. Kako bi se formulirala primjerena teorijska i empirijska podloga za razumijevanje empirijskog istraživanja utjecaja cijena nafte na makroekonomske pokazatelje u Republici Hrvatskoj, na koncu je dan i pregled postojećih istraživanja o utjecaju cijena nafte na pojedine makroekonomske pokazatelje, a što predstavlja temelj za postavljanje istraživačkih hipoteza.

2.1. ENERGIJA I GOSPODARSKI RAST

Iako nafta ima najveći udio u globalnoj energetskoj strukturi proizvodnje i potrošnje energije (*EIA, 2016*), nužno je za početak sagledati širu sliku, odnosno razmotriti postojeće spoznaje o vezi energije (općenito) i gospodarskog rasta. Iste su, stoga, iznijete u nastavku.

2.1.1. Važnost energije s aspekta gospodarskog rasta

Proizvodni proces podrazumijeva transformaciju materije (iz jednog oblika u drugi) što zahtijeva energiju (*Cleveland et al., 2000*). Navedeno se može protumačiti kao primjena zakona termodinamike u ekonomskoj teoriji koji implicira da je energija nužan preduvjet svih oblika proizvodnje[5]. Sve društvene pa i ekonomske aktivnosti prožete su različitim vidovima energije koja povezuje proizvodne i uslužne djelatnosti (*Cottrel, 1955*). Ako bi se iz ovog spleta međuovisnosti uklonila energija kao vezivno tkivo, svakodnevica kakvu poznajemo radikalno

[5] Za detaljan pregled primjene zakona termodinamike u ekonomskoj teoriji *cf. Ayres i Warr, 2009; Kummel, 2011; Hall i Klitgaard, 2012.*

bi se promijenila. Upravo zato, u suvremenom svijetu energija (njena dostupnost kao i učinkovitost) predstavlja okosnicu ekonomske aktivnosti (*Abaidoo, 2011*).

O važnosti energije svjedoči i značajan rast njene potrošnje, posebice od druge polovine 20. stoljeća (*Malanima, 2014*). Štoviše, nastavak ovakvog trenda očekuje se i u desetljećima koja slijede (*EIA, 2016*). Paralelni procesi ekspanzije svjetske populacije, snažnog gospodarskog rasta (dosada neviđenog u povijesti ljudske civilizacije) kao i znakovitih strukturnih promjena (deagrarizacije, industrijalizacije, urbanizacije, globalizacije) nesporno su zaslužni za snažan rast potrošnje energije (*Hajko et al., 2018*), a zasigurno će doprinijeti i daljnjem rastu potrošnje. U srednjem roku, ovome će ponajviše doprinijeti rast azijskih ekonomija, primarno Kine i Indije (*BP, Statistical Review of World Energy, 2019*).

O važnosti energije u odnosu na gospodarski rast svjedoče i podaci o njihovu bliskom kretanju prikazani Grafikonom 2.1.1.1. kojim su naznačene postotne godišnje promjene realnog BDP-a, potrošnje energije i energetske intenzivnosti na globalnoj razini. Iz prikazanog se naočigled mogu izvući dva temeljna zaključka. Prvi se odnosi na pozitivnu vezu stopa gospodarskog rasta i stopa rasta potrošnje energije. Drugi se zaključak odnosi na evidentan pad energetske intenzivnosti[6] (količina utrošene energije po jedinici realnog BDP-a) koji, očekivano, započinje usporedno s pojavom prvih naftnih šokova 70ih godina prošlog stoljeća.

Trend smanjenja energetske intenzivnosti važan je s aspekta povezanosti potrošnje energije i gospodarskog rasta jer svjedoči o promjenama u proizvodnoj strukturi u korist ušteda energije (kao posljedica neizvjesnosti kretanja njenih cijena, ali i raspoloživosti iste). U posljednjim je desetljećima evidentan znatan napredak po pitanju smanjenja energetske intenzivnosti i rasta energetske učinkovitosti mnogih razvijenih ekonomija kao i ekonomija u razvoju (*Stern, 2010b*). Na tom je tragu nužno naznačiti i faktore koji potencijalno determiniraju (jačaju ili slabe) vezu između energije i gospodarskog rasta (*Stern, 2010a*); stupanj supstitucije energije i ostalih proizvodnih inputa (uz postojeći stupanj razvoja tehnologije), tehnološki

[6] Općenito se smatra da energetska intenzivnost predstavljena krivuljom ima zvonoliki oblik implicirajući rastuću energetsku intenzivnost kako gospodarstvo realno raste da bi potom, na višoj razini razvoja, ponovno došlo do pada iste (*Lescaroux, 2011*).

napredak/promjena, promjene u strukturi potrošnje energije i promjene u strukturi gospodarskog outputa.

Grafikon 2.1.1.1.: Postotne godišnje promjene realnog BDP-a, potrošnje energije i energetske intenzivnosti u svijetu

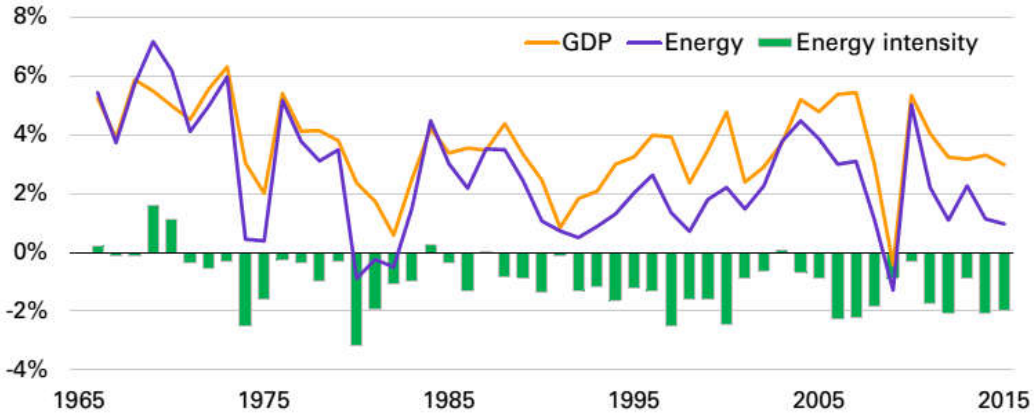

Izvor: British Petroleum, BP Statistical Review of World Energy (2015)

O važnosti energije u svim aspektima društvenog i gospodarskog razvoja svjedoči i uloga institucija (*Vlahinić-Dizdarević i Žiković, 2010*) koje definiraju institucionalne okvire kojima usmjeravaju tokove i strukturu proizvodnje, potrošnje i razmjene energije, na nacionalnoj (Zakon o energiji, NN 120/12, 14/14, 95/15, 102/15, 68/18; Zakon o tržištu nafte i naftnih derivata, NN 19/14, 73/17, 96/19; Zakon o trošarinama, NN 106/18,..) ali i supranacionalnoj razini (Kyoto protokol[7], Strategija Europa 2020[8], Pariški sporazum o klimatskim promjenama[9]). Nositelji politike višim porezima i trošarinama na neobnovljive energente (o čijem su uvozu uglavnom ovisni) pokušavaju minimizirati negativne efekte rasta cijena energenata. Zakonskim aktima uvode se obveze stvaranja strateških zaliha energenata (Zakon o tržištu nafte i naftnih derivata, NN 19/14, 73/17, 96/19) kako bi se spriječiti negativni efekti eventualnih zastoja u opskrbi istima, a potiče se i energetski učinkovito korištenje energije (Zakon o energiji NN 120/12, 14/14; Zakon o energetskoj učinkovitosti, NN 127/14). Jednako se tako nastoji potaknuti korištenje vlastitih obnovljivih izvora energije kako bi se minimizirala uvozna ovisnost o neobnovljivim izvorima energije kao i potakla supstitucija neobnovljivih

[7] Usvojen u prosincu 1997. godine, Protokol je stupio na snagu 2005. godine. Industrijske zemlje obvezale su se na smanjenje emisije stakleničkih plinova (ugljični dioksid, metan, dušični oksid, hidrofluorokarbonati, perfluorokarbonati i sumporni heksafluoridi) za prosječno 5 % u razdoblju između 2008. i 2012. u usporedbi s razinama iz 1990-ih.

[8] Smanjenje emisija stakleničkih plinova za najmanje 20%, povećanje udjela obnovljivih energija na 20% i povećanje energetske učinkovitosti za 20% (*COM(2010) 2020 final*).

[9] Pariški sporazum globalni je sporazum o klimatskim promjenama koji je 12. prosinca 2015. postignut u Parizu. Obuhvaća razdoblje od 2020. nadalje.

izvora energije obnovljivima (Zakon o obnovljivim izvorima energije i visokoučinkovitoj kogeneraciji, NN 100/15, 123/16, 131/17, 111/18). Stvaranje učinkovitog i transparentnog institucionalnog okvira koji će tržište učiniti konkurentnijim, potaknuti investicije te stimulrati tehnološku dufuziju, uz istovremenu zaštitu interesa potrošača pokazalo se ključnim elementom reformi u energetskom sustavu (*Vlahinić-Dizadarević i Žiković, 2011, str. 13*).

Političke odluke značajno utječu na ponudu i potražnju za energijom zbog čega, pored populacijskih trendova, gospodarskog rasta i tehnološkog napretka, uvijek trebaju biti uzete u obzir kao jednako važne (*Schult-Bornemann, 2012*). Energija je nezamjenjiva u procesu stvaranja dodane vrijednosti pri čemu je energetska učinkovitost ključna, ne samo za rast poduzeća ili gospodarstva već općenito za postizanje cilja održivog razvitka. Upravo zbog toga, poboljšanje energetske učinkovitosti, a posljedično i rast učinkovitosti u korištenju prirodnih resursa, postaju važni izazovi energetske, ekonomske i ekološke politike. Razumijevanju uloge energije u ekonomskom rastu tako je doprinijela i institucionalna ekonomija kroz istraživanja utjecaja institucionalnih struktura na efikasno korištenje energije te razvoj i implementaciju energetski učinkovitih tehnologija (*Paavola i Adger, 2005*).

Stabilan ekonomski rast zahtijeva rast potrošnje energije osim ako energetska učinkovitost raste brže od samog outputa (*Zon i Yetkiner, 2003*). Iako empirijska istraživanja (*cf. Newell et al., 1999; Popp, 2001*) svjedoče o pozitivnom utjecaju rasta cijena energije na razvitak energetski efikasnih tehnologija, u obzir treba uzeti i *tzv. rebound efect*. Navedeni učinak nalaže da uslijed porasta energetske učinkovitosti, a kao posljedica niza bihevioralnih i sistemskih reakcija potrošača energije, dolazi do rasta potrošnje energije (*Khazoom, 1980; Saunders, 1992; Binswanger, 2001; Font Vivanco et al, 2016*).

Grafikonom 2.1.1.1. prikazana veza energije i gospodarskog rasta ne otkriva smjer utjecaja; potiče li rast potrošnje energije gospodarski rast ili gospodarski rast potiče rast potrošnje energije. Počevši od naftnih šokova 70ih godina prošlog stoljeća, veza energije (primarno njene količine, odnosno potrošnje) i gospodarskog rasta u fokusu je ekstenzivne akademske debate. Tematikom uzročnosti potrošnje energije i gospodarskog rasta (*engl. the energy-growth nexus)* bavi se izniman broj istraživanja čiji je pregled ponuđen u nastavku (vidjeti poglavlje *2.1.3. Pregled istraživanja o uzročnosti energije i gospodarskog rasta*). Ipak, kao teorijsku podlogu za pregled istraživanja o utjecaju cijena globalno najzastupljenijeg energenta, nafte, na

gospodarski rast, a jednako tako i empirijsko istraživanje ove disertacije, nužno je ukazati na ulogu energije u teorijama rasta, prezentiranu u nastavku.

2.1.2. Uloga energije u teorijama rasta

S obzirom na njenu nespornu teorijsku i praktičnu važnost, može se zaključiti da energija predstavlja značajan temelj ekonomskog rasta i razvoja (*Imran i Siddiqui, 2010*; *Jakovac i Vlahinić Lenz, 2015; Walheer, 2018*). Ni rad ni kapital ne mogu funkcionirati (proizvoditi) bez energetskog inputa. Stoga je energija jednako važna kao rad i kapital i u tom bi se smislu trebala tretirati kao jednako važan proizvodni input (*Ayres et al., 2013*). Pa ipak, promatrajući postojeće teorijske spoznaje kao i modele ekonomskog rasta, lako se može uvidjeti da je uloga energije u ekonomskoj teoriji (i modelima rasta) podcijenjena[10].

Prevladavajući (*engl. mainstream*) modeli rasta uopće ne uzimaju u obzir energiju (*Stern, 2010b*). Čak ni osnovni model ekonomskog rasta za kojeg je *Solow (1956)* dobio Nobelovu nagradu uopće ne uključuje energiju i tzv. energetske resurse, već se isti smatraju intermedijarnim dobrom. Iako je navedeni model naknadno proširen neobnovljivim i obnovljivim resursima, kao takav nije imao svoju primjenu u standardnoj makroekonomiji (*Ayres i van den Bergh, 2005*; *Stern i Kander, 2012*; *Jakovac i Vlahinić Lenz, 2016*), a prošireni su se modeli rasta uglavnom razmatrali u kontekstu zaštite okoliša (*Ockwell, 2008*). Uloga energije s aspekta ekonomskog rasta u neoklasičnoj je ekonomiji stoga minorna *(Stern i Cleveland, 2004).*

Solowljev neoklasični model rasta (*1956*), koji se smatra začetkom moderne teorije rasta, promatra proizvodnju dobara i usluga kao funkciju rada i kapitala s ključnim doprinosom egzogenog faktora – ukupne faktorske proizvodnosti (*engl. Total Factor Productivity - TFP*). Prema Solowljevoj agregatnoj funkciji proizvodnje, stope rasta gospodarstva razlučene su na doprinos kapitala i rada ekonomskom rastu. Ipak, zbroj doprinosa kapitala i rada nije jednak ukupnoj stopi ekonomskog rasta. Navedena se razlika pojašnjava upravo ukupnom faktorskom proizvodnošću. Jedna od ključnih pretpostavki neoklasičnog modela rasta podrazumijeva i opadajuće prinose na kapital zbog čega se doprinos investicija gospodarskom rastu smanjuje do točke saturacije. Od navedene točke nadalje, jedini izvor daljnjeg rasta je tehnološki

[10] Za detaljan pregled uloge energije u teorijama rasta vidjeti *Jakovac i Vlahinić Lenz, 2016*, str. 11-48. ili *Stern, 2010b*

napredak (ili rast ukupne faktorske produktivnosti) kojeg model ne pojašnjava već tretira kao egzogenog. S obzirom na pretpostavku o opadajućim prinosima na kapital, gospodarstva s višim realni BDP-om po stanovniku trebala bi rasti po nižoj stopi od siromašnijih gospodarstva zbog čega bi, kroz vrijeme, trebala nastupiti njihova konvergencija (*Barro i Sala-i-Martin, 1995*). S obzirom da do očekivane konvergencije navedenih kategorija gospodarstava nije došlo (*Acocella, 2005, str. 167.*), ekonomisti su se okrenuli reviziji neoklasične teorije rasta pokušavajući prvenstveno endogenizirati tehnološki napredak, odnosno ukupnu faktorsku proizvodnost (*Mervar, 1999*).

Prva su rješenja ponudili *Romer (1986; 1990)*, i *Lucas (1988)* navodeći izostanak navedene konvergencije gospodarstava različitog stupnja ekonomske razvijenosti kao temeljnu motivaciju u svojim pokušajima modeliranja rasta, što se smatra začetkom endogenih teorija rasta. Endogene teorije rasta pretpostavljaju da su sile koje moderiraju rast endogeni rezultat ekonomskog sustava (pri tome je napuštena ograničavajuća pretpostavka neoklasičnih modela rasta o opadajućim prinosima na kapital). *Barro i Sala-i-Martin (1995)* izdvajaju tri osnovne skupine endogenih modela rasta (iako je njihov razvoj još uvijek u tijeku); modeli zasnovani na eksternalijama (*cf. Romer, 1986, 1987; Lucas, 1988; Scott, 1991; Lucas, 1993*) modeli zasnovani na istraživanju i razvoju (*cf. Romer, 1990; Grossman i Helpman, 1990, 1991; Aghion i Howitt, 1992*) i AK modeli u kojima je pozornost usmjerena na široko definiran pojam kapitala, uključujući ljudski i fizički kapital, kao sredstvo generiranja rasta (*cf. Becker, Murphy i Tamura, 1990; Jones i Manuelli, 1990; King i Rebelo, 1990; Rebelo, 1991*).

Prema *Alamu (2006),* neoklasična ekonomija percipira energetske resurse kao analitički ekvivalentne inputima koji ne pridonose ikakvu energiju u procesu proizvodnje (poput stakla, željeza, plastike i sl.). Nužno je ipak naznačiti pojedine relevantne neoklasične modele rasta koji su preispitivali realnost pretpostavke održivog rasta u svjetlu smanjenja raspoložive količine ograničenih prirodnih resursa. Debata oko utjecaja oskudnosti na dugoročni gospodarski rast tradicionalno se naslanja na oskudnost neobnovljivih prirodnih resursa *(Smulders, 2004).* Radovi *Stiglitza (1974), Solowa (1974), Dasgupta i Heala (1974)* uspostavili su referentni neoklasični okvir za proučavanje oskudnosti prirodnih resursa. Istaknuti radovi, kao ni kasniji (*cf. Aghion i Howitt, 1998; Valente i Di Maria, 2008*), ipak ne specificiraju o kojim je oskudnim prirodnim resursima riječ. Drugim riječima, nigdje se decidirano ne spominje energija.

Stiglitz (1980) navodi da je za postojanje problema ograničenja prirodnih resursa nužno ispunjavanje temeljne pretpostavke o neobnovljivosti prirodnih izvora kao i nemogućnosti njihove supstitucije. Pri tome neoklasično poimanje podrazumijeva očekivanje da će rast cijene ograničenog resursa racionalizirati njihovu potrošnju (povećati energetsku učinkovitost) kao i supstituciju. S obzirom da je u vrijeme nastanka ovih teorija energija u razvijenim zemljama bila dostupna i relativno jeftina, ovakva ograničenja nisu se smatrala značajnima (*Stern i Kander, 2012*). *Stern (2010b)* tvrdi da pretpostavka supstitucije oskudnog resursa, točnije energije, nije realna jer je elastičnost supstitucije energije, odnosno prirodnog i fizičkog kapitala, niska. Isto potvrđuju i *Koetse et al. (2008*). Ograničenja u mogućnostima supstitucije, u slučaju njihova postojanja, rezultiraju stoga ograničavanjem rasta koji se može kompenzirati jedino tehnološkim napretkom – rastom energetske učinkovitosti (*Smulders, 2004*). Pored navedenog, koncept jake održivosti nalaže da se niz proizvoda i usluga proizvedenih uz pomoć energije i ostalih prirodnih resursa ne mogu, čak ni teorijski, alternativno proizvesti supstitucijom navedenih resursa radom i kapitalom (*Hartwick, 1978*).

Neoklasično je poimanje, nadalje, podrazumijevalo i da će savršeno efikasno tržište (mehanizmom cijena) pravodobno inicirati tehnološke inovacije što će onemogućiti nepovoljan utjecaj ograničene dostupnosti i/ili rasta cijena oskudnih resursa na ekonomski rast (*Cleveland i Costanza, 2008; Hall i Klitgaard, 2006*). Na ovom je mjestu nužno podsjetiti i na ranije spomenuti tzv. *rebound effect* koji pojašnjava da rast energetske učinkovitosti rezultira rastom potrošnje energije, a ne smanjenjem iste. *Ockwell (2008)* dodaje i kritiku neoklasične perspektive realnog rasta koja zanemaruje činjenicu da se proizvodnja odvija unutar okvira zadanih raspoloživošću i dostupnošću prirodnih resursa, na taj način zanemarujući zakone termodinamike. Energiju je stoga nužno promatrati kao ključan proizvodni input.

Unatoč pažnji koju su, barem naizgled, prirodni resursi dobili u proširenim neoklasičnim modelima rasta, njihovi kritičari, počevši od *Georgescu-Roegena (1971; 1975),* navode da ekonomska teorija zanemaruje činjenicu da se prirodni resursi nepovratno troše što ujedno rezultira i štetnim učincima za okoliš. Ekološka ekonomija[11], proizašla iz ovih kritika, zagovara stav da fizička dimenzija ekonomske proizvodnje zahtijeva puno veću pozornost u teoriji

[11] Ekološka ekonomija je granična znanost između ekonomije i ekologije koja preispituje fundamentalne odnose bioloških i fizičkih sustava stavljajući u centar pozornosti kakvoću života a ne isključivo gospodarstvo i profit. Ona promatra svijet prirode i društva na izrazito drukčiji način od konvencionalne ekonomije (*Črnjar i Črnjar, 2009, str. 352.*)

ekonomskog rasta koja proizlazi iz razmjene energije i materije između ekonomskog sustava i njegove okoline (*Jakovac i Vlahinić Lenz, 2016*). Ona naglašava važnost očuvanja prirodnog kapitala koji, prema ekološkim ekonomistima, predstavlja nadopunu klasičnoj definiciji kapitala kao podlozi za stvaranje dodane vrijednosti (*Ayres i Warr, 2009*).

Postojeća teorijska stajališta o ulozi energije u gospodarskom rastu evidentno su kontradiktorna. Dok se s aspekta ekoloških ekonomista energija smatra ključnim proizvodnim inputom, samim time i izvorom gospodarskog rasta (*Ayres i Warr, 2005, 2009; Cleveland et al., 1984; Hall et al., 1986, 2001; Murphy i Hall, 2010*), neoklasični ekonomisti ne smatraju energiju faktorom rasta, pa tako ni njegovim ograničenjem (*Solow, 1956, Aghion i Howitt, 1998; Barro i Sala-i-Martin, 2003; Stern i Cleveland, 2004; Mankiw, 2006; Stern, 2011b*).

Pojedina istraživanja ipak uključuju energiju u proizvodne funkcije (*cf. Hudson i Jorgenson, 1974; Jorgenson, 1984; Berndt i Wood, 1979; Stern, 1993, 2000, 2011b; Lee (2005), Apergis et al. (2010), Acemoglu et al., 2012; Lin et al., 2013; Fallahi i Voia, 2015; Calel i Dechezlepretre (2016), Esso i Keho (2016), Bretschger et al (2017), Bretschger i Schaefer (2017), Du i Lin, 2017; Costa-Campi et al., 2018),* unatoč različitom načinu uključivanja energije. Važno je naznačiti da navedena istraživanja, osim energije, kao proizvodne inpute uključuju i rad i kapital kako bi se izbjeglo ispuštanje važnih objasnidbenih varijabli. Njihov se značaj u proizvodnoj funkciji ne pokušava minorizirati. Naprotiv, promatrajući energiju kao preduvjet ekonomskog razvoja i rasta (što je posebno vidljivo uslijed poremećaja u opskrbi energijom) u proizvodne se funkcije, pored primarno rada i kapitala, dodaje energija kao proizvodni input.

Kao odgovor na naftne šokove iz 1970ih nekoliko je ekonomista uključilo energiju u svoje modele u vidu tzv. KLEM proizvodnih funkcija, gdje se K odnosi na kapital, L na rad, E na energiju, a M na materijale (*Hudson i Jorgenson, 1974; Jorgenson, 1984; Berndt i Wood, 1979).* Ovakvi su pokušaji kritizirani primarno niskim udjelom troškova energije u ukupnom BDP-u većine zemalja OECD-a (4-5%) što nije moglo opravdati uključivanje energije u vidu proizvodnog (a ne intermedijarnog) inputa *(Denison, 1979). Ayres et al. (2013)*, primjerice, navode pristup uvažavanja inputa u proizvodnu funkciju sukladno udjelu njegovih troškova u BDP-u potpuno pogrešnim pozivajući se na nerealne pretpostavke mogućnosti (najčešće neograničene) supstitucije proizvodnih inputa koja je u stvarnosti relativno niska jer je proizvodnost rada i kapitala uslijed smanjenja raspoložive energije ozbiljno je narušena.

Također, u novije se vrijeme pokušava odvojeno sagledati utjecaj obnovljivih i neobnovljivih izvora energije na ekonomski rast. Ova istraživanja također (zasada) ukazuju na nepostojanje znanstvenog konsenzusa. Postojeći rezultati se tako mogu kategorizirati u tri skupine ovisno o tome jeli detektiran utjecaj (količine potrošnje) energije (obnovljive ili neobnovljive) na gospodarski rast; pozitivan, obostran ili ni ne postoji (za pregled istraživanja *cf. Adewuyi i Awodumi, 2017 i Kahia et al., 2017*).

Ističući fokus akademske rasprave o utjecaju cijena nafte na makroekonomske pokazatelje (obrađene u sklopu poglavlja *2.2. Mehanizmi utjecaja cijena nafte na gospodarstvo*), kao teorijske podloga provedenom empirijskom istraživanju, na ovom će mjestu biti posebno istaknut model rasta *Berka i Yetkinera (2013)* koji ne samo da uzima u obzir energiju već i njene cijene. Navedeni autori modificiraju *Rebelov (1991)* endogeni model ekonomskog rasta koji se, kao i njihov, svrstava u kategoriju AK modela.

Model *Berka i Yetkinera (2013*) je dvosektorski model sektora potrošnih i investicijskih dobara u zatvorenoj ekonomiji, bez uplitanja vlade. Sektor potrošnih dobara koristi kapital i energiju kao inpute, dok sektor investicijskih dobara koristi fizički kapital i izvor je endogenog rasta u ekonomiji[12]. Poziciju energije u modelu autori argumentiraju činjenicom da je upravo sektor potrošnje (transport i potrošnja kućanstava) odgovoran za veći dio energetske potrošnje. Model nadalje pretpostavlja da cijene energije (neovisno o tome dali je riječ o obnovljivim ili neobnovljivim izvorima) rastu po konstantnoj egzogeno zadanoj stopi sukladno kalkulacijama *Zona i Yetkinera (2003)*.

Berk i Yetkiner (2013) definiraju proizvodnu funkciju investicijskog sektora jednadžbom:

$$Y_I = A \quad K_I \tag{2.1.}$$

gdje Y_I predstavlja output investicijskog sektora, A je faktorska proizvodnost, a K_I šira definicija fizičkog kapitala kojeg koristi investicijski sektor. Potrošna se dobra proizvode korištenjem fizičkog kapitala (K_C)[13] i energije (E) uz pretpostavku konstantnih prinosa na obujam:

[12] Kapital podrazumijeva širu definiciju kapitala u koju je uključen ljudski i fizički kapital.

[13] Pretpostavlja se da je ukupan fizički kapital (K_I+K_C) u potpunosti iskorišten.

$$Y_C(\equiv C) = K_C^{\alpha} \quad E^{1-\alpha} \tag{2.2.}$$

Iz profitne jednadžbe investicijskog sektora, $\Pi_I = p_I \quad A \quad K_I \quad R_I \quad K_I$, proizlazi da je

$$p_I \quad A = R_I \tag{2.3.}$$

U jednadžbi (2.3.), R_I je nominalna stopa rente fizičkog kapitala u proizvodnji investicijskog sektora, a p_I je cijena invensticijskih dobara. Za svaki K_I mora biti zadovoljen uvjet $p_I \quad A = R_I$. Iz profitne jednadžbe sektora potrošnih dobara, $\Pi_C = p_C \quad K_C^{\alpha} \quad E^{1-\alpha} \quad R_C \quad K_C \quad R_E \quad E$ proizlazi da je:

$$R_C = p_C \quad \alpha \quad K_C^{\alpha-1} \quad E^{1-\alpha} \tag{2.4.}$$

$$R_E = p_C \quad (1 \quad \alpha) \quad K_C^{\alpha} \quad E^{-\alpha} \tag{2.5.}$$

U jednadžbama (2.4.) i (2.5.), R_C je nominalna stopa rente fizičkog kapitala u proizvodnji potrošačkih dobara, R_E je nominalna cijena energije, a p_C cijena potrošnih dobara. Realna je cijena energije (q), po uzoru na *Zon i Yetniker (2003)*, definirana kao $q = \frac{R_E}{p_C}$ uz pretpostavku rasta po konstantnoj stopi ($\hat{q} > 0$) kao i pretpostavku neograničene dostupnosti energije uz zadane cijene energije. Stopa rente fizičkog kapitala u oba sektora ne mora biti jednaka, stoga vrijedi:

$$R_I \equiv R_C \Rightarrow p_I \quad A = p_C \quad \alpha \quad K_C^{\alpha-1} \quad E^{1-\alpha} \Rightarrow \alpha \quad K_C^{\alpha-1} \quad E^{1-\alpha} \tag{2.6.}$$

Iz jednadžbe (2.6.) proizlazi da je $p = (\alpha \quad 1)\widehat{K}_C + (1 \quad \alpha)\hat{E}$, gdje p, $\widehat{K}_C$ i $\hat{E}$ predstavljaju stope rasta relativnih cijena investicijskih dobara (p), kapitala (K_C) i energije (E) koje koristi sektor potrošačkih dobara. Daljnjom matematičkom razradom modela autori dolaze do sljedećih rješenja (za detaljnu matematičku elaboraciju modela cf. *Berk i Yetkiner (2013):*

$$\hat{E} = \frac{1}{\theta}(A \quad \delta \quad \rho \quad \frac{(1-\alpha+\alpha\theta)}{\alpha}\hat{q}) \equiv g' \tag{2.7.}$$

$$\widehat{K}_C = \frac{1}{\theta}(A \quad \delta \quad \rho \quad \frac{(1-\alpha)(1-\theta)}{\alpha}\hat{q}) \equiv g \tag{2.8.}$$

$$\hat{C} = \hat{Y}_C = \frac{1}{\theta}\left(A \quad \delta \quad \rho \quad \frac{(1-\alpha)}{\alpha}\hat{q}\right) \equiv ag + (1 \quad \alpha)g' \tag{2.9.}$$

pri čemu je $\hat{q}$ stopa rasta cijena energije[14]. Navedene tri jednadžbe impliciraju negativan utjecaj cijena energije na stopu potrošnje energije, kako tvrde i *Zon i Yetkiner (2003).* Konačno, autori definiraju vremensku putanju kretanja realnog BDP-a kao:

$$Y = const1 \quad e^{[ag+(1-\alpha)g\prime]\,t} \tag{2.10.}$$

gdje je $const1 = p(0) \quad Y_I(0) + (K_C(0))^{\alpha} \quad (E(0)^{1-\alpha}$ set inicijalnih vrijednosti modela. Zaključno: 1) ukupan kapital, investicijski i potrošački, raste po stopi g, 2) potražnja za energijom raste po stopi g', 3) realni BDP, kao i potrošnja, rastu po stopi $ag + (1 \quad \alpha)g'$ pri čemu 4) stopa rasta cijena energije ($\hat{q}$) negativno utječe na prethodne tri. Drugim riječima, uključujući energiju u svoj dvosektorski endogeni model rasta, *Berk i Yetkiner (2013)* ukazuju na negativan utjecaj stope rasta cijena energije na endogene stopa rasta BDP-a i potrošnje energije.

Korištenjem godišnjih podataka o kompozitnim cijenama energije, BDP-u po stanovniku i potrošnji energije po stanovnika, svoj teorijski model autori su potkrijepili i empirijskom provjerom istog za 15 zemalja[15] u periodu od 1978. do 2011. Rezultati iste, koji navode negativan i statistički značajan utjecaj cijena energije nak BDP kao i potrošnju energije po stanovniku (u dugom roku), potvrđuju navode iznesenog teorijskog modela.

Uvažavajući iznesene konstatacije o nepostojanju znanstvenog konsenzusa o ulozi energije u teorijama rasta, kao i njenom marginaliziranju od strane tzv. *mainstream* teorija rasta, u nastavku je dan pregled istraživanja o uzročnosti energije i gospodarskog rasta.

2.1.3. Pregled istraživanja o uzročnosti energije i gospodarskog rasta

Istraživanja o uzročnosti (*engl. causality*) potrošnje energije i gospodarskog rasta inicirali su naftni šokovi 1970ih godina prošlog stoljeća kada se i javlja prvo istraživanje međuodnosa potrošnje energije i gospodarskog rasta u SAD-u (*Kraft i Kraft, 1978*). Od istaknutog pionirskog

[14] δ je stopa deprecijacije kapitala.
[15] Australija, Austrija, Belgija, Kanada, Danska, Francuska, Italija, Japan, Nizozemska, Norveška, Portugal, Španjolska, Švedska, Ujedinjeno Kraljevstvo i SAD.

rada Krafta i Kraft niz istraživanja se, kako na pojedinačnim tako i na većem broju gospodarstava, bavio navedenom tematikom. Štoviše, upravo su istraživanja o uzročnosti potrošnje energije i gospodarskog rasta izvor kontroverzi u području makroekonomike energetike jer rezultati postojećih istraživanja nisu ponudili nedvojbene zaključke o navedenoj tematici (*Carmona et al., 2016*). O brojnosti navedenih studija, kao i heterogenosti korištenih uzoraka, vremenskih perioda i, konzekventno, zaključaka, svjedoče i studije navedene u sklopu Tablice 2.1.2.1. Za detaljnije rasprave o navedenoj tematici vidjeti: *Ozturk (2010), Payne (2010), Chen et al. (2012), Pirlogea, (2012), Jakovac (2013), Bouoiyour et al. (2014), Kalimeris et al. (2014), Menegaki (2014), Omri (2014) i Hajko (2017).* Navedena je tematika u posljednje vrijeme i dodatno dobila na važnosti usporedno s razvojem sofisticiranijih ekonometrijskih metoda.

Uobičajeno se empirijski ispituju četiri različite vrste veze između količine energije i gospodarskog rasta: 1) hipoteza rasta (*engl. growth hypothesis*), 2) hipoteza očuvanja (*engl. conservation hypothesis*), 3) hipoteza povratnog utjecaja (*engl. feedback hypothesis)* i, konačno, 4) hipoteza neutralnosti (*engl. neutrality hypothesis)* (cf. *Ozturk, 2010; Payne, 2010, Gozgor et al., 2018; Barnabé, 2018; Shahbaz et al., 2018)* [16].

Dakle, smjer uzročnosti između potrošnje energije i gospodarskog rasta dulje je vrijeme predmet akademskih rasprava u području makroekonomike energetike. Ta činjenica ni ne čudi kad se uzme u obzir značaj implikacija ovog tipa istraživanja za vođenje ekonomske i energetske politike, pojašnjenih u nastavku.

Hipoteza rasta podrazumijeva jednosmjerni utjecaj potrošnje energije na gospodarski rast, stoga ograničenja potrošnje energije mogu inverzno utjecati na gospodarski rast (smanjenje potrošnje energije umanjuje stope realnog gospodarskog rasta, a vrijedi i obratno). Ova hipoteza ukazuje na značajnu ulogu energije u gospodarskom rastu koju promatra kao komplementaran proizvodni input u odnosu na rad i kapital. Ako je ova hipoteza točna, može se konstatirati da je energija limitirajući faktor gospodarskog rasta, odnosno da energetski cjenovni šokovi, koji

[16] Pojašnjenja hipoteza prema *Ozturk, 2010 i Payne, 2010.*

zbog djelovanja efekta dohotka neminovno umanjuju potrošnju energije, djeluju limitirajuće na gospodarski rast.

Hipoteza očuvanja podrazumijeva uzročnost od gospodarskog rasta ka potrošnji energije što znači da uporaba energija nije limitirajući faktor, već nusprodukt gospodarskog razvitka. Ako je ova hipoteza točna, mogu se usvajati politike usmjerene na reduciranje korištenja energije (smanjenje energetske intenzivnosti i povećanje energetske učinkovitosti gospodarstva) jer se smatra da energija ima vrlo skroman ili nikakav utjecaj na realni rast.

Važnost energije i njene učinkovite uporabe je ključna s aspekta gospodarskog rasta i održivog razvoja pri čemu je upravo pitanje (poboljšanja) energetske učinkovitosti postalo jedno do najvažnijih izazova energetske, ekonomske i ekološke politike (*Borozan, 2018*).

Hipoteza povratnog utjecaja detektira obostrani utjecaj potrošnje energije i gospodarskog rasta što bi podrazumijevalo njihovo istovremeno kretanje, dok hipoteza neutralnosti podrazumijeva nepostojanje veze između potrošnje energije i gospodarskog rasta.

Kombinirajući i nadopunjujući analizu *Ozturka (2010), Paynea (2010)* i *Jakovca (2013)* u Tablici 2.1.3.1. kronološkim su slijedom navedena značajnija istraživanja navedene tematike. Već kratkim proučavanjem rezultata istraživanja obuhvaćenih ovim pregledom nameće se, i ranije istaknut, zaključak o nepostojanju znanstvenog konsenzusa oko smjera uzročnosti između potrošnje energije i gospodarskog rasta. Ponekad i drastične razlike u rezultatima postojećih istraživanja mogle bi se pripisati analizi različitih gospodarstava, varijabli, vremenskih perioda i/ili, kako navodi *Ozturk (2010),* različitih ekonometrijskih pristupa.

Tablica 2.1.3.1. Pregled istraživanja o uzročnosti potrošnje energije i gospodarskog rasta

Autor(i)	**Analizirano gospodarstvo i period analize**	**Rezultati analize***
Kraft i Kraft (1978)	SAD (1947-1974)	BDP → potrošnja energije
Ackra i Long (1980)	SAD (1950-1970)	Nema uzročnosti
Yu i Hwang (1984)	SAD (1947-1979)	Nema uzročnosti
Abosedra i Baghestani (1989)	SAD (1947-1987)	BDP → potrošnja energije
Hwang i Gum (1991)	Tajvan (1961-1990)	BDP ↔ potrošnja energije
Yu i Jin (1992)	SAD (1974-1990)	Nema uzročnosti
Stern (1993)	SAD (1947-1990)	BDP → potrošnja energije
Cheng (1995)	SAD (1947-1990)	Nema uzročnosti

Masih i Masih (1996)	Malezija (1955-1990), Filipini (1955-1991) i Singapur (1960-1990)	Nema uzročnosti
	Indonezija (1960-1990), Pakistan (1955-1990)	BDP ↔ potrošnja energije
Cheng (1997)	Brazil (1963-1993)	Potrošnja energije → BDP
	Meksiko (1949-1993) i Venezuela (1952-1993)	Nema uzročnosti
Cheng i Lai (1997)	Tajvan (1955-1993)	BDP → potrošnja energije
Glasure i Lee (1997)	Južna Koreja i Singapur (1961-1990)	Nema uzročnosti Potrošnja energije → BDP
Masih i Masih (1997)	Koreja (1961-1990) i Tajvan (1961-1990)	BDP ↔ potrošnja energije
Cheng (1998)	Japan (1952-1995)	BDP → potrošnja energije
Masih i Masih (1998)	Šri Lanka i Tajland (1955-1991)	Potrošnja energije → BDP
Cheng (1999)	Indija (1952-1995)	
Asafu-Adjaye (2000)	Indija, Indonezija i Turska (1973-1995)	Potrošnja energije → BDP
	Tajland i Filipini (1971-1995)	BDP ↔ potrošnja energije
Soytas et al. (2001)	Turska (1960-1995)	Potrošnja energije → BDP
Stern (2000)	SAD (1948-1994)	Potrošnja energije → BDP
Yang (2000)	Tajvan (1954-1997)	BDP ↔ potrošnja energije
Aqueel i Butt (2001)	Pakistan (1955-1996)	BDP → potrošnja energije
Fatai et al. (2002)	Novi Zeland (1960-1999)	Nema uzročnosti
Glasure (2002)	Koreja (1961-1990)	BDP ↔ potrošnja energije
Hondroyiannis et al. (2002)	Grčka (1960-1999)	BDP ↔ potrošnja energije
Soytas i Sari (2003)	Argentina (1950-1990)	BDP ↔ potrošnja energije
	Koreja i Italija (1953-1991)	BDP ↔ potrošnja energije
	Turska, Francuska, Japan i Njemačka (1950-1992)	Potrošnja energije → BDP
	Indonezija (1960-1992), Poljska (1965-1994), Kanada, UK i SAD (1950-1992)	Nema uzročnosti
Altinay i Karagol (2004)	Turska (1950-2000)	Nema uzročnosti
Fatai et al. (2004)	Indija i Indonezija (1960-1990)	Potrošnja energije → BDP
	Australija i Novi Zeland (1960-1990)	BDP → potrošnja energije
	Tajland i Filipini (1960-1990)	BDP ↔ potrošnja energije
Ghali i El-Sakka (2004)	Kanada (1961-1997)	BDP ↔ potrošnja energije
Oh i Lee (2004)	Koreja (1970-1999)	BDP ↔ potrošnja energije
Paul i Bhattacharya (2004)	Indija (1950-1996)	BDP ↔ potrošnja energije
Wolde-Rufael (2004)	Shanghai (1952-1999)	BDP → potrošnja energije
Hatemi-J i Irandoust (2005)	Švedska (1965-2000)	BDP → potrošnja energije
Lee i Chang (2005)	Tajvan (1954-2002)	Potrošnja energije → BDP
Lee (2005)	18 zemalja u razvoju (1975-2001)	Potrošnja energije → BDP
Lee (2006)	Njemačka, UK, Švedska, SAD, Belgija, Nizozemska, Kanada, Švicarska, Francuska, Italija, Japan (1975-2001)	Nema uzročnosti BDP ↔ potrošnja energije Potrošnja energije → BDP BDP → potrošnja energije
Soytas i Sari (2006)	Njemačka, Francuska, SAD,	BDP → potrošnja energije Potrošnja energije → BDP

	Kanada, Italija, Japan, UK (1960-2004)	BDP ↔ potrošnja energije
Ho i Siu (2007)	Hong Kong (1966-2002)	Potrošnja energije → BDP
Jobert i Karanfil (2007)	Turska (1960-2003)	Nema uzročnosti
Lee i Chang (2007)	22 razvijene zemlje (1965-2002), 18 zemalja u razvoju (1971-2002)	BDP ↔ potrošnja energije BDP → potrošnja energije
Mehrara (2007)	11 zemalja izvoznica nafte: Iran, Kuvajt, Ujedinjeni Arapski Emirati, Saudijska Arabija, Bahrein, Oman, Alžir, Nigerija, Meksiko, Ekvador, Venezuela (1971-2002)	BDP → potrošnja energije
Zamani (2007)	Iran (1967-2003)	BDP → potrošnja energije
Ang (2008)	Malezija (1971-1999)	BDP → potrošnja energije
Chiou-Wei et al.(2008)	Filipini i Singapur (1971-2003)	BDP → potrošnja energije
	SAD (1960-2003), Tajland i Koreja (1971-2003)	Nema uzročnosti
	Tajvan (1954-2006) i Hong Kong (1971-2003)	BDP ↔ potrošnja energije
Erbaykal (2008)	Turska (1970-2003)	Potrošnja energije → BDP
Huang et al. (2008)	82 gospodarstva niske, srednje i visoke razine dohotka (1972-2002)	Nema uzročnosti BDP → potrošnja energije
Lee et al. (2008)	22 OECD zemlje	BDP ↔ potrošnja energije
Lee i Chang (2008)	16 Azijskih ekonomija; dugi rok, kratki rok (1971-2002)	Potrošnja energije → BDP Nema uzročnosti
Narayan i Smith (2008)	G7 (1972-2002)	Potrošnja energije → BDP
Bowden i Payne (2009)	SAD (1949-2006)	Potrošnja energije → BDP
Odhiambo (2009)	Tanzanija (1971-2006)	Potrošnja energije → BDP
Gelo (2009)	Hrvatska (1953-2005)	BDP → potrošnja energije
Payne (2009)	SAD (1949-2006)	Nema uzročnosti
Zhang i Cheng (2009)	Kina (1960-2007)	BDP → potrošnja energije
Odhiambo (2010)	Južna Afrika i Kenija (1972-2006)	Potrošnja energije → BDP
	Kongo (1972-2006)	BDP → potrošnja energije
Tsani (2010)	Grčka (1960-2006)	Potrošnja energije → BDP
Imran i Siddiqui (2010)	Bangladeš, Indija i Pakistan (1971-2008)	BDP → potrošnja energije
Vlahinić-Dizdarević i Žiković (2010)	Hrvatska (1993-2006)	BDP → potrošnja energije
Žiković i Vlahinić Dizdarević (2011)	Belgija, Danska, Irska, Norveška, Švedska, Hrvatska, Latvija, Litva, Moldavija, Slovenija	BDP → potrošnja energije
	Austrija, Češka, Slovačka, Malta, Bugarska, Bosna i Hercegovina[17]	Potrošnja energije → BDP
Ying et al. (2011)	Kina (1954-1997)	BDP → potrošnja energije
Kakar i Khilji (2011)	Pakistan (1980-2009)	Potrošnja energije → BDP
Narayan et al. (2012)	93 zemlje (1980-2006)	Nema uzročnosti[18]
Borozan (2013)	Hrvatska (1992-2010)	Potrošnja energije → BDP
Jakovac (2013)	Hrvatska (1952-1989) Hrvatska (1993-2010)	Potrošnja energije → BDP BDP → potrošnja energije

[17] Period analize za razvijene zemlje: 1980-2007, za tranzicijske zemlje: 1993-2007

[18] Ističući heterogenost rezultata među različitim ekonomijama, u većini zemalja potvrđena je hipoteza neutralnosti. Kod gospodarstava kod kojih je detektirana uzročnost, autori konstatiraju da potrošnja energije negativno utječe na BDP.

Vlahinić i Jakovac (2014)	Hrvatska (1952-2011)	Potrošnja energije → BDP (dugi rok) BDP ↔ potrošnja energije (kratki rok)
Carmona et al. (2017)	SAD (1973-2015)	BDP ↔ potrošnja energije
Stjepanović (2018)	30 zemalja (1994-2016)	Potrošnja energije → BDP

*„Potrošnja energije → BDP" podrazumijeva potvrdu hipoteze rasta; „BDP → potrošnja energije" podrazumijeva potvrdu hipoteze očuvanja, „BDP ↔ potrošnja energije" podrazumijeva potvrdu hipoteze povratnog utjecaja i „Nema uzročnosti" podrazumijeva potvrdu hipoteze neutralnosti
Izvor: Obrada autorice prema *Ozturk (2010), Payne (2010)* i *Jakovac (2013)*

S obzirom na uzorak ovog istraživanja, nužan je poseban osvrt na istraživanja *Gele (2009), Vlahinić-Dizdarević i Žikovića (2010), Žiković i Vlahinić-Dizdarević (2011), Borozan (2013), Jakovca (2013) i Vlahinić i Jakovca (2014)* o odnosu potrošnje energije i gospodarskog rasta u Hrvatskoj. Zaključci navedenih istraživanja se razlikuju što je, moguće, posljedica korištenja različitog metodološkog pristupa i/ili perioda analize.

Gelo (2009) je koristeći VAR metodologiju i test Granger uzročnosti analizirao uzročnost potrošnje energije i gospodarskog rasta u Hrvatskoj u periodu od 1953. do 2005. godine te zaključio da gospodarski rast Granger uzrokuje potrošnju energije, kao i da ukupna potrošnja energije i konstanta VAR modela nisu statistički značajne, za razliku od BDP-a. Do sličnih su rezultata došli i *Vlahinić-Dizdarević i Žiković (2010)* koji su istraživali uzročnost između nekoliko energetskih pokazatelja (potrošnja energije u industriji i kućanstvima, potrošnja nafte, primarna proizvodnja energije i neto uvoz energije) i realnog BDP-a u periodu od 1993. do 2006. Navedeni autori pronalaze kointegraciju između energije (predstavljene navedenim energetskim pokazateljima) i realnog BDP-a kao i uzročnost u smjeru od realnog BDP-a prema ostalim korištenim energetskim pokazateljima.

U nešto kasnijem istraživanju isti su autori (*Žiković i Vlahinić-Dizdarević, 2011*) korištenjem modela korekcije pogreške istraživali odnos između potrošnje nafte i gospodarskog rasta za 22 mala europska gospodarstva, uključujući Hrvatsku, u periodu od 1980. do 2007. godine. Iako rezultati istraživanja upućuju na heterogenost među analiziranim gospodarstvima (u smislu smjera uzročnosti), Hrvatska se i ovoga puta, kao i u ranije navedenom istraživanju istih autora, smjestila unutar grupe analiziranih gospodarstava kod kojih je detektirana uzročnost u smjeru od realnog BDP-a prema potrošnji nafte.

Suprotno navedenom, *Borozan (2013)*, koristeći bivarijanti VAR model kao i test Granger uzročnosti u periodu od 1992. do 2010., tvrdi da ukupna potrošnja energije u Hrvatskoj Granger

uzrokuje realni BDP. Iste godine *Jakovac (2013)* analizira postojanje Granger uzročnosti (i smjera iste), kao i kointegracije, između ukupne potrošnje energije i realnog BDP-a u dva perioda; od 1952. do 1989., te od 1993. do 2010. Autor u prvom periodu detektira kointegraciju među varijablama te daljnjom analizom i korištenjem modela korekcije pogreške konstatira da postoji uzročnost u smjeru od potrošnje energije prema realnom BDP-u. U drugom periodu ne pronalazi dokaze o postojanju kointegracije, no u daljnjoj ekonometrijskoj analizi, korištenjem VAR modela, odnosno Grangerovog testa uzročnosti, zaključuje da rast potrošnje energije pozitivno utječe na rast realnog BDP-a. Zaključci *Jakovca (2013)* o uzročnosti između potrošnje energije i gospodarskog rasta u Hrvatskoj od samostalnosti naovamo, u suglasju su sa zaključcima *Gele (2009) i Vlahinić-Dizdarević i Žiković (2010).*

Vlahinić i Jakovac (2014) za period od 1952. do 2011. godine ispituju međuodnos gospodarskog rasta (realnog BDP-a) s jedne, te proizvodnih inputa: rada, kapitala i energije (predstavljene ukupnom potrošnjom energije) s druge strane. Njihovi rezultati potvrđuju dugoročan pozitivan odnos i kointegraciju proizvodnih inputa i gospodarskog rasta kao i značajnu ulogu energije u odnosu na gospodarski rast. Isti autori navode da je, kao i kod *Borozan (2013),* u dugom roku smjer Granger uzročnosti od potrošnje energije prema BDP-u, dok u kratkom roku konstatiraju postojanje povratnog utjecaja.

Konačno, *Stjepančić (2018)* panel analizom analizira međuodnos energetskih pokazatelja i BDP u 31 europskoj državi[19] u periodu od 1994. do 2016. Temeljem dobivenih rezultata istraživanja, autor zaključuje da postoji visok stupanj korelacije između potrošnje energije i BDP-a (u smjeru od potrošnje energije prema BDP-u) u tranzicijskim gospodarstvima EU, uključujući i hrvatsko. S druge strane, u razvijenim zemljama ne detektira značaj navedenog odnosa što pojašnjava činjenicom da su iste već dosegnule prilično visoku razinu razvijenosti pri kojoj potrošnja energije nema značajan utjecaj na veličinu BDP-a.

Navedeni rezultati impliciraju da je energija nužan preduvjet gospodarskog rasta. Također, smanjenje potrošnje energije moglo bi se, u tom slučaju, negativno odraziti na realni gospodarski rast kako u kratkom tako i u dugom roku. Sukladno navedenom Hrvatska bi trebala

[19] Belgija, Bugarska, Češka, Danska, Njemačka, Estonija, Irska, Grčka, Španjolska, Francuska, Hrvatska, Italija, Cipar, Latvija, Litva, Luksemburg, Mađarska, Malta, Nizozemska, Austrija, Poljska, Portugal, Rumunjska, Rusija, Slovenija, Slovačka, Finska, Švedska, Ujedinjeno Kraljevstvo, Island i Norveška.

usvojiti politike usmjerene ka povećanju investiranja u energetski sektor i energetski efikasnije industrijske grane (*Vlahinić i Jakovac, 2014*).

Ako su pak istiniti rezultati *Gele (2009), Vlahinić-Dizdarević i Žiković (2010)* i *Jakovca (2013),* jednosmjerna Granger uzročnost od realnog rasta BDP-a ka potrošnji energije bi značila da politike usmjerene na reduciranje potrošnje energije kao i stupnja uvozne ovisnosti o energiji ne bi trebale polučiti negativne efekte na realni gospodarski rast. Ipak, kako navode *Vlahinić-Dizdarević i Žiković (2010),* ovakvi se rezultati mogu dovesti i u direktnu vezu sa snažnom tranzicijskom depresijom i de-industrijalizacijskim procesima iz 1990ih koji su rezultirali snažnim padom industrijske proizvodnje i, s time povezanim, neminovnim padom potrošnje energije. Posljedično, uzročnost potrošnje energije i realnog BDP-a u većoj je mjeri povezana s transportnim sektorom nego s energetskom potražnjom industrijskog sektora.

U svakom slučaju, kao što je vidljivo iz svega iznesenog, i na globalnoj razini i u Hrvatskoj istraživanja uzročnosti potrošnje energije i gospodarskog rasta nisu jednoznačna, zbog čega njihove zaključke valja uzeti s dozom opreza. Oprečnost rezultata postojećih istraživanja trebala bi stoga poslužiti kao poticaj za daljnje istraživanje navedene problematike, prvenstveno korištenjem alternativnih metodologija, ali i kompleksnijeg multivarijantnog okruženja[20] kao i istraživanjima na sektorskim razinama.

U konačnici, s obzirom da pojedini autori navedenih istraživanja kao uporište nepostojanju znanstvenog konsenzusa oko veze energije i gospodarskog rasta navode korištenje pokazatelja potrošnje (količine) energije, a ne njenih cijena (*Walheer, 2018*), u nastavku je fokus usmjeren upravo na utjecaj cijena nafte (kao još uvijek najzastupljenijeg energenta) na gospodarstvo. Kao temelj za opravdanost ovakvog pristupa, ali i ponovna potvrda važnosti cijena energije, može se istaknuti i navod *Joblinga i Jamasba (2017*) koji procjenjuju globalni trošak potrošnje energije na 3,65 bilijuna dolara godišnje, što čini oko 5% globalnog BDP-a.

[20] Uvažavajući i ostale potencijalno važne varijable poput: cijene energenata, broja stanovnika, regulatornog okvira i sl.

2.2. MEHANIZMI UTJECAJA CIJENA NAFTE NA MAKROEKONOMSKE POKAZATELJE

Cijene nafte mogu utjecati (i utječu) na gospodarstva na različite načine i kroz različite kanale. Počevši od naftnih kriza 1970ih, istraživanja kanala utjecaja cijena nafte na gospodarstvo razvijala su se u različitim smjerovima.

Većina prezentiranih istraživanja vrše empirijske provjere postavljenih hipoteza u multivarijantnom okviru, pri čemu se nerijetko u isti model uključuje i više od jednog makroekonomskog pokazatelja. Iz tog razloga je moguće iz pojedinih istraživanja polučiti zaključke vezane za različite (a opet povezane) makroekonomske pokazatelje. U ovom je poglavlju stoga, između ostalog, izvršena i svojevrsna dekonstrukcija navedenih istraživanja kako bi se zaključci istih mogli sagledati s aspekta utjecaja cijena nafte na pojedini makroekonomski pokazatelj.

Kvalitativna analiza utjecaja cijena nafte na makroekonomske pokazatelje dana je kroz prezentiranje postojeće literature na zadanu temu i teorijsku elaboraciju prezentiranih mehanizama utjecaja uz napomenu da su rijetka istraživanja koja se u pojedinim segmentima referiraju na utjecaj cijena nafte na pojedine hrvatske makroekonomske pokazatelje elaborirana u sklopu poglavlja *3. Analiza makroekonomskih pokazatelja hrvatskog gospodarstva.* U nastavku je ponuđen pregled istraživanja i postojećih teorijskih i empirijskih spoznaja o utjecaju cijena nafte na odabrane makroekonomske pokazatelje; BDP, inflaciju, nezaposlenost, osobnu potrošnju i investicije. Konačno, pojašnjen je i termin asimetričnog utjecaja cijena nafte na gospodarstvo kao i mogući uzroci istog.

2.2.1. Implikacije promjena cijena nafte na gospodarski rast

O utjecaju energije na gospodarski rast kao i značaju nafte unutar energetske strukture već je bilo riječi u prethodnim poglavljima. Ovdje su, kroz relevantna istraživanja navedene tematike, prikazani načini utjecaja cijena nafte na gospodarski rast, odnosno kronološki pregled istih.

Interes za istraživanje utjecaja cijena nafte na gospodarski rast koincidirao je s naftnim šokovima 1970ih godina. Kako je istovremeno u SAD-u došlo do recesije, znanstvenici su pokušali ustanoviti postoji li inverzna veza između kretanja cijena nafte, odnosno naftnih šokova, i realnog gospodarskog rasta. Među prvim studijama utjecaja cijena nafte na

gospodarstvo može se istaknuti ona *Rasche i Tatoma (1977*), koji konstatiraju značajan i trajan efekt naftnog šoka s prijelaza 1973. na 1974. na gospodarstvo SAD-a. Iako kao inicijalnu reakciju gospodarstva navode rast inflacije, pažnju ipak usmjeravaju na značajan pad realnog BDP-a (kao i popratni rast nezaposlenosti/pad zaposlenosti). Mehanizam kojim navedeni autori (kojima se kasnije pridružuju i *Brown i Yuckel, 1999 i Beaudreau, 2005)* pojašnjavaju utjecaj cijena nafte na gospodarstvo je tzv. klasični makroekonomski šok na strani ponude. Prema ovoj teoriji, porast cijena nafte signalizira oskudnost energenata koji su ujedno jedan od ključnih inputa u proizvodnji. Kao posljedica, rast proizvodnje i produktivnosti su usporeni.

Snaga ovog efekta ovisi o udjelu troškova nafte u jediničnim troškovima (u proizvodnom procesu) kao i o stupnju supstitucije proizvodnih inputa[21], a upravo se visok stupanj komplementarnosti nafte u odnosu na preostale proizvodne čimbenike[22] navodi kao ograničavajući faktor rasta. Efekt se nadalje, kao posljedica pada razine proizvodnje, prelijeva i na tržište rada kroz porast nezaposlenosti, odnosno pad zaposlenosti. Središnja kritika ovakve percepcije naftnog šoka je udio troškova nafte u proizvodnji (BDP-u) koji je nedovoljan da bi se pojasnile snažnije fluktuacije realnog BDP-a. *Kilian i Vigfuson (2013),* primjerice, navode da se u SAD-u navedeni udio od 1973. kretao u rasponu od minimalno 1% do maksimalno 8%. U Hrvatskoj, primjerice, udio troškova nafte kao postotak BDP-a čini oko 5% (5,88% u 2007. i 4,35% u 2008; izračun autorice[23]), što je ekvivalentno svjetskoj praksi (u SAD-u 2009. je iznosio 4% BDP-a; *Hamilton, 2010).* Unatoč tome, kod pojedinih gospodarstava promjene cijena nafte rezultiraju snažnim oscilacijama realnog outputa, što do sada ponuđeni modeli bazirani na agregatnoj ponudi nisu u mogućnosti pojasniti (*Kilian, 2008a; Barsky i Kilian, 2004*).

Inverzan odnos cijena nafte i realnog BDP-a (u SAD-u) potvrdile su i studije *Morka i Halla (1980),* te *Darbya (1982).* Nešto kasnije studije *(Gisser i Goodwin, 1986; Burbidge i Harrison, 1984)* također su potvrdile ranije zaključke o postojanju inverzne veze između porasta cijena

[21] *Berndt i Wood (1975; 1979) i Wilcox (1983)* u svojim istraživanjima nude dokaze o snažnoj komplementarnosti energije i kapitala u SAD-u kako prije, tako i nakon 1973.
[22] *Broadstock et al. (2007),* kroz meta analizu 375 različitih istraživanja o mogućnosti supstitucije proizvodnih inputa, ističu da se energija i kapital generalno ponašaju kao komplementi ili slabi supstituti.
[23][(ukupna potrošnja nafte u barelima, prema: US Energy Information Administration, International Energy Statistics) x (prosječna cijena barela nafte u promatranoj godini; prema: US Energy Information Administration, International Energy Statistics, Annual F.O.B. (Free on Board) Spot Price of Brent Crude Oil in Europe) x (godišnji prosjek deviznog tečaja HRK/USD; prema HNB Tečajna lista, Statistike tečaja)]/(BDP u mil. kn u tekućim cijenama; prema HNB, Statistika, Ekonomski indikatori) x 100.

nafte i gospodarskog rasta. Ipak, kao najutjecajniju studiju iz ovoga vremena valja istaknuti Hamiltonovu iz 1983. godine. Koristeći VAR model (1948-1982), *Hamilton (1983)* je ustanovio postojanje jake negativne korelacije između rasta cijena nafte i stopa realnog gospodarskog rasta SAD-a, kao i stopa nezaposlenosti. Nadalje, isti autor ističe kako korelacija između cijena nafte i ekonomskog rasta za razdoblje od 1948. do 1972. nije slučajnost te da je sedam od osam poslijeratnih recesija[24] u SAD-u uslijedilo nedugo (tri do četiri tromjesečja) nakon snažnog rasta cijena nafte. Također se navodi nepostojanje dokaza o potencijalnom utjecaju neke treće makroekonomske varijable koja bi mogla istovremeno rezultirati rastom cijena nafte i, nedugo zatim, padom realnog outputa. Konačno, Hamilton zaključuje da su, čak i ako nisu bile jedini i isključivi uzrok gospodarskih recesija, rastuće cijene nafte, u najmanju ruku, determinirale duljinu trajanja, jačinu, ali i vrijeme početka recesija.

Gisser i Goodwin (1986) ističu da u periodu od 1961. do 1982. g. cijene nafte i dalje imaju potencijal predviđanja stope rasta BDP-a (u SAD-u). Oni, između ostalog, smatraju da poduzete mjere monetarne i fiskalne politike ne mogu u cijelosti objasniti efekte poskupljenja nafte na gospodarstvo. U skladu s tim, autori zaključuju da naftni cjenovni šokovi osim proinflatornih pritisaka na gospodarstvo imaju i dodatan (negativan) utjecaj na razinu proizvodnje (u vidu smanjenja razine outputa) uzrokujući pomak krivulje agregatne ponude u lijevo (prema dolje).

Kasnija istraživanja (i dalje prvenstveno u SAD-u) koja su obuhvatila dulje vremenske nizove podataka (točnije, koji su za početak, uvrstili podatke iz 1980ih), ističu slabljenje veze između cijena nafte i makroekonomskih pokazatelja *(Lee et al., 1995; Hooker, 1996).* S obzirom na gotovo očiglednu važnost energije, primarno nafte, i njenog troška za gospodarstvo znanstvenici su zaključili da je (u 1980im) očito došlo do promjena u prirodi odnosa cijena nafte i BDP-a te se fokusirali na pronalaženje alternativnih specifikacija pokazatelja cijena nafte, kao i relacija (metodologije) kojima bi se mjerio utjecaj cijena nafte na BDP. *Rotemberg i Woodford (1996*) ističu i oslabljenu moć OPEC-a u održavanju stabilnih nominalnih cijena nafte, zbog čega se snažne varijacije na strani potražnje za naftom brzo (puno brže) pretaču u promjene nominalnih cijena nafte.

Kao odgovor na pronalaženje alternativnih specifikacija pokazatelja cijena nafte javlja se nekoliko potencijalnih rješenja. *Mork (1989)* među prvima sugerira postojanje asimetričnosti

[24] Nakon 2. svjetskog rata

utjecaja cijena nafte na BDP (SAD; 1949:Q1-1988:Q2), što do 1980ih i nije moglo biti zamijećeno budući da su se promjene cijena nafte sastojale gotovo isključivo od porasta cijena, pa su u takvim uvjetima i linearni modeli (pokazatelji) mogli adekvatno procijeniti relaciju između kretanja cijena nafte i BDP-a. Navedeni autor, čiji je pokazatelj korišten i u ovom istraživanju, odvojeno promatra periode rasta i periode pada cijena nafte te zaključuje da je reakcija stopa rasta BDP-a na rast cijena nafte negativna i statistički značajna, za razliku od reakcije BDP-a na pad cijena nafte koja je, iako pozitivna, puno skromnija i k tome nije statistički značajna. Na ovaj je način ponovno dokazana veza gospodarskog rasta i cijena nafte.

Lee et al. (1995) naglašavaju važnost metodološkog uvažavanja povećane volatilnosti cijena nafte dajući pri tome važnost i efektu iznenađenja[25]. Ako niska volatilnost cijena na naftnim tržištima prethodi snažnom porastu cijena, utjecaj na gospodarstvo će biti puno snažniji, negoli da se rast cijena dogodio u uvjetima visoke volatilnosti. Prema autorima, navedeno će rezultirati realokacijom proizvodnih resursa i padom agregatnog outputa (barem u fazi trajanja realokacije resursa). S druge strane, u periodima visoke volatilnosti realnih cijena nafte racionalni agenti ne pribjegavaju alokaciji resursa jer tekuće cijene sadrže nedovoljno informacija temeljem kojih bi se mogla predvidjeti njihova buduća vrijednost. Modeliranjem odvojenih nizova pada i rasta cijena nafte GARCH[26] metodologijom (i u ovom je istraživanju korišten navedeni pokazatelj), autori mjere nepredvidivost promjene cijena nafte (varijabla mjeri intenzitet promjene cijena nafte u tekućem u odnosu na prethodno razdoblje) kao i uvjetnu vremensku varijancu (*engl. time-varying conditional variance*) promjena cijena nafte. Jednostavnijim rječnikom, predložena varijabla odražava promjenu uzorka ponašanja cijena nafte u odnosu na prethodno razdoblje. Autori dokazuju da je upravo efekt iznenađenja promjena cijena nafte ključan u njihovom utjecaju na gospodarstvo SAD-a (1949:Q3 – 1992:Q3). Vrlo slične rezultate dobiva i *Hooker (1996).*[27]

Hamilton (1996) potom uvodi pokazatelj (u sklopu odjeljka 4.2.2. detaljno opisan) koji u potpunosti zanemaruje pad cijena nafte (ima ugrađenu pretpostavku asimetrije) kao i utjecaj

[25] Specifikacija efekta iznenađenja daje veliku važnost čak i manjim promjenama cijena ako one nastupe nakon dužeg perioda stabilnih cijena.
[26] **G**eneralized **A**uto**R**egressive **C**onditional **H**eteroskedasticity (GARCH) model
[27] *Hooker (1996)* tvrdi da u razdoblju od 1948. do 1972. g. razina cijena nafte kao i njihova promjena imaju značajan negativan utjecaj na rast BDP-a u SAD-u. Ipak za poduzorak od 1973.do 1994., Hooker tvrdi da veza u potpunosti slabi, pri čemu čak ni Morkova (1989) specifikacija asimetrije ne nudi stabilnu relaciju utjecaja cijena nafte na BDP. No, uvažavanjem volatilnosti cijena nafte, Hooker ponovno dobiva stabilnu (negativnu) vezu između rasta cijena nafte i BDP-a, ističući da je ključna volatilnost (a ne razina) cijena nafte.

porasta cijene nafte ako ista ne premašuje vlastitu maksimalnu vrijednost u četiri prethodna vremenska perioda. Na taj je način stavljen naglasak kako na asimetriju, tako i na efekt iznenađenja u utjecaju cijena nafte na realno gospodarstvo. Ovaj pokazatelj, čak i kad se uzmu u obzir kompletno dostupne vremenske nizove podataka, nudi stabilnu vezu između kretanja cijena nafte i BDP-a u SAD-u (1948:Q1-1994:Q2). Za recentnije podatke i *Rahman i Serletis (2010)* potvrđuju da (u periodu od 1983:M01-2008:M12) pored cijena nafte i volatilnost cijena nafte negativno utječu na makroekonomsku aktivnost SAD-a pri čemu, prema autorima, monetarna politika doprinosi asimetriji spomenutog utjecaja.

Kako je razvidno iz navedenih studija, volatilnost cijena nafte, barem što se tiče SAD-a, ima u novijem periodu sve značajniji utjecaj na gospodarska kretanja. *Hamilton (2000)* ipak naglašava da još uvijek nema dovoljno povijesnog iskustva (podataka) kako bi se mogla izolirati samo jedna najbolja relaciju za pojašnjavanje utjecaja cijena nafte na gospodarstvo, što je posebno važno prilikom modeliranja i analize utjecaja cijena nafte na makroekonomske pokazatelje.

Među novijim utjecajnim radovima javljaju se i dokazi da nisu važni (samo) smjer i intenzitet promjene cijena nafte već i njihov uzrok. Ispitujući utjecaj cijena nafte na uzorku SAD-a (koristeći VAR metodologiju) *Kilian (2009),* razlikuje tri temeljne vrste naftnih šokova, ovisno o njihovom uzroku (SAD; 1975-2007). Prva je vrsta šok na strani ponude sirove nafte (*engl. oil-supply shock*) kod kojeg se kreće od pretpostavke da su sve značajnije fluktuacije u promjenama cijena nafte posljedica poremećaja u količini ponude te da su uglavnom rezultat političkih previranja na Bliskom Istoku (i relativno nepredvidivog ponašanja OPEC-a). Zbog navedenog, primjerice, *Hamilton (2003)* smatra da se cijene nafte treba tretirati kao egzogene kod svih neto uvoznica. S druge strane, *Kilian (2008a, 2008b)* navodi da kvantitativne mjere naftnih šokova na strani ponude (asociranih s previranjima na Bliskom Istoku) imaju slabu moć predviđanja[28] postotnih promjena realne cijene nafte[29]. Zbog navedenog, inicijalno *Barsky i Kilian (2002)* identificiraju šokove na strani potražnje, odnosno naftne šokove koji su posljedica

[28] Samo se naftni šok na strani ponude početkom 1990ih može smatrati značajnim (*Kilian i Murphy, 2014*).
[29] Štoviše, *Kilian (2014)* navodi da mjere naftnog šoka na strani ponude koje analiziraju *Hamilton (2003)* i *Kilian (2008b*) pojašnjavaju tek 25% rasta cijena nafte na prijelazu 1973. na 1974. godinu.

kretanja globalne ekonomske aktivnosti[30] (*engl. oil-demand shocks driven by global economic* activity ili, kako ih kasnije *Kilian (2014)* preimenuje u *engl. flow demand shocks)*, smatrajući ih ključnom determinantom kretanja cijena nafte[31]. Konačno, kao treća vrsta naftnog šoka, predlaže se šok na strani potražnje vođen očekivanjima o budućim cijenama nafte – špekulacijama (*engl. oil-specific demand shock*)[32]. Ovaj je pristup tek nedavno privukao pažnju akademskih krugova (*Kilian, 2009; Alquist i Kilian; 2010, Archanskaïa et al., 2012; Knittel i Pindyck, 2013; Kilian i Lee, 2014*). *Kilian (2009)* konačno zaključuje da šokovi na strani ponude, kao i špekulativni šokovi na strani potražnje, imaju očekivan utjecaj na gospodarski rast. S druge strane, šok na strani potražnje vođen snažnom ekonomskom aktivnošću u kratkom roku povećava output (dok ga ostali šokovi smanjuju!). Ovaj zaključak je dijametralno suprotan onome što se do tada smatralo uobičajenim utjecajem rastućih cijena nafte na gospodarski rast. Pri tome su znanstvenici bili fokusirani na pretpostavku da promjene cijena nafte proistječu iz egzogenih promjena u ponudi nafte. U novije je vrijeme tako sve više prihvaćen stav da su cijene nafte pod utjecajem potražnje za naftom, a ne samo njene ponude (*cf. Barsky i Kilian, 2004; Hamilton, 2003; Hamilton, 2009; Kilian, 2014*).

Hamilton (2009) nadalje ističe da je i ključni mehanizam utjecaja cijena nafte na ekonomiju na strani potražnje (ne ponude), kroz poremećaje potrošnje kućanstava i poduzeća, i to potrošnje neenergetskih dobara i usluga. Polazi se od pretpostavke da rast cijena nafte umanjuje raspoloživi dohodak (jer se više novca troši na naftu/naftne derivate), što umanjuje i potrošnju ostalih dobara i usluga. Snaga utjecaja bi pri tom ovisila o cjenovnoj elastičnosti potražnje za naftom. No, čak i kada se pretpostavi savršena cjenovna neelastičnost potražnje, efekt je ograničen relativno skromnim udjelom troškova energije u ukupnim troškovima kućanstva (za SAD to je u prosjeku 6%). Na tom tragu *Edelstein i Kilian (2009)* zaključuju da je pad osobne potrošnje nedovoljan kako bi se pojasnio ukupan pad realnog BDP-a te da cijene nafte, iako su za njeno kretanje značajne, ne predstavljaju ključnu determinantu kretanja osobne potrošnje. Na tragu navedenog su i navodi niza autora (*Hamilton, 1988; Dhawan i Jeske, 2008; Edelstein*

[30] *Kilian (2009)* globalnu ekonomsku aktivnost mjeri indeksom koji samostalno kreira temeljem globalnog prometa teretnih brodova. Rast indeksa podrazumijeva rast globalne ekonomske aktivnosti. Vrijedi i obratno. Visina odstupanja indeksa od nule nema ekonomsko značenje, važan je samo smjer kretanja indeksa u odnosu na njegovu prethodnu vrijednost.

[31] Potvrde potonje konstatacije mogu se naći i kod *Kilian i Murphy (2012), Kilian i Hicks (2013), Baumeister i Peersman (2013), Kilian i Murphy (2014) i Kilian i Lee (2014).*

[32] *Kilian i Murphy (2014)* tvrde da su špekulativni šokovi na strani potražnje imali važnu ulogu u drugom dijelu 1979. i 1990. dok ne pronalaze uporišta u prilog špekulativne potražnje za naftom kao izvora rasta cijena nafte od 2003. do polovine 2008.

i Kilian, 2009; Bodenstein i Guerrieri, 2011) o snažnoj reakciji potrošnje trajnih potrošnih dobara na promjene cijena nafte, koja se u konačnici gotovo isključivo svodi na (statistički značajne negativne) reakcije u potražnji za automobilima.

U stvarnosti, tumačenje naftnih šokova bilo kao šokova na strani ponude ili na strani potražnje ne udovoljava u potpunosti uobičajenoj percepciji makroekonomske reakcije gospodarstva na naftne šokove, a ista podrazumijeva recesijsko i proinflatorno djelovanje naftnih šokova. Ako se naftni šok promatra kao šok na strani ponude, u klasičnom AS-AD modelu dolazi do pomicanja krivulje AS (agregatna ponuda) u lijevo čime se uspostavlja ravnoteža uz niži realni BDP i višu razinu cijena. Ako istovremeno slabi potražnja, AD krivulja (agregatna potražnja) se također povlači u lijevo čime se smanjuje proinflatorni pritisak, a u obzir svakako treba uzeti i mjere monetarne politike. Ako monetarna politika reagira podizanjem kamatne stope, ovo dodatno može usporiti realni rast kroz negativan utjecaj na osobnu potrošnju i investicije (*Tang et al., 2009*). Iz ovoga je razvidno i koliko je u stvarnosti teško točno procijeniti stupanj prelijevanja rasta cijena nafte na inflaciju (o navedenom utjecaju više u narednom poglavlju). Nadalje, *Lee i Ni (2002)* tvrde da energetski intenzivna gospodarstva apsorbiraju utjecaj porasta cijena nafte kao šokove na strani ponude, a energetski efikasnija gospodarstva kao šokove na strani potražnje.

Promatranje naftnog šoka u kontekstu šoka na strani ponude i potražnje podrazumijeva direktne efekte šoka na gospodarstvo. Pored navedenih prisutni su i tzv. indirektni efekti; tzv. efekt realokacije, efekt neizvjesnosti (utjecaj na očekivanja) i efekt odgovora monetarne politike na naftni šok. Efekt realokacije ujedno je i prvo teorijsko pojašnjenje asimetrije u odgovoru gospodarstva na naftne šokove. Smanjena potrošnja energetski intenzivnih trajnih dobara (poput automobila) uzrokuje sektorske realokacije rada i kapitala prema ostalim sektorima (*Hamilton, 1988; Edelstein i Kilian, 2007; 2009*). Kako je sama vrijednost kupnje automobila puno veća od troška (poskupljenja) goriva, čak i manje promjene cijena nafte mogu rezultirati značajnijim reakcijama u potražnji za automobilima pa tako i sektorskim realokacijama. Međutim, udio troškova za kupnju automobila je relativno skroman u odnosu na ukupnu potrošnju, zbog čega ovaj efekt teško može pojasniti reakciju BDP-a na promjene cijena nafte, posebno kad se uzme u obzir da jačina efekta ovisi i o zastupljenosti automobilskog sektora u ukupnom gospodarstvu (*Kilian, 2014*). Efekt neizvjesnosti naslanja se na tumačenje reakcije prvenstveno investicija na promjene cijena nafte (neovisno o smjeru promjene cijena nafte!) te također pojašnjava asimetričnu reakciju gospodarstva na promjene cijena nafte; rast

neizvjesnosti glede budućih cijena nafte rezultira odgađanjem ili čak i odustajanjem od investicija (*Bernake, 1983; Pindyck, 1991; Ferderer, 1996*). Neizvjesnost također utječe i na potražnju (potrošnju) gdje se u uvjetima rasta neizvjesnosti odgađa planirana potrošnja trajnih dobara, a također može doći i do rasta štednje, što dodatno umanjuje potrošnju. Konačno efekt monetarne politike ovisi o načinu kako monetarne vlasti reagiraju na promjene cijena nafte, primarno naftne šokove. Važnost monetarne politike pri apsorpciji naftnih šokova uočena je vrlo rano. *Pierce i Enzler (1974)* tako pojašnjavaju tzv. *real balance efekt* tvrdeći da rast cijena nafte generira povećanu potražnju za novcem. Nesposobnost i/ili nemogućnost monetarne politike da reagira adekvatnim rastom ponude novca rezultira većim kamatnim stopama što reducira i osobnu i investicijsku potrošnju i, naravno, realni gospodarski rast. Na istom tragu i *Kilian i Lewis (2009)* i *Herrera i Pesavento (2009),* vršeći dekompoziciju fluktuacija outputa industrijskih ekonomija, sugeriraju da je utjecaj cijena nafte na output vezan upravo s monetarnom politikom koja je potencijalno i uzrok heterogenosti rezultata istraživanja utjecaja cijena nafte na realno gospodarstvo (o važnosti monetarne politike pri apsorpciji naftnih šokova više u poglavljima 2.2.2. i 2.2.6.).

Gotovo sve prethodno navedene studije rađene su mahom na uzorku SAD-a. Uvažavajući činjenicu da različite ekonomije na različiti način ovise o nafti, a pored toga ih karakteriziraju i različite: industrijske strukture, strukture ponude primarne energije, mikro i makro ekonomske politike, strukture tržišta rada i formalnih i neformalnih institucija, nužno je svakako uzeti u obzir istraživanja na ostalim ekonomijama koja su značajno zaostajala sve od 2000ih naovamo. Od pomoći je svakako i prociklički karakter produkcije znanstvenih radova iz navedene tematike čija brojnost, kao i interes akademske zajednice za problematiku, raste usporedno s rastom cijena nafte, a ista ulaskom u treće tisućljeće pokazuje uzlazni trend.

Nakon inicijalnih studija *Darby (1982)*[33] i *Burbidge i Harrison (1984)*[34]*,* koji pronalaze slične, iako slabije izražene negativne korelacije naftnih šokova i realnog rasta u SAD-u (*Hamilton, 1983*), kao prva važnija studija van SAD-a može se istaknuti istraživanje *Morka, Olsena i*

[33] SAD, UK, Kanada, Francuska, Njemačka, Italija, Japan i Nizozemska (1957:Q1-1976:Q1)
[34] SAD, UK, Kanada, Njemačka i Japan (1961:M01-1982:M06)

Mysena (1994). Potonji autori navode negativan utjecaj naftnih šokova na realnu ekonomiju (za većinu statistički značajan) zemalja iz uzorka[35], te za iste nude i dokaz asimetrije.

Koristeći VAR metodologiju na primjeru Grčke (1989:M01 - 1999:M06), *Papapetrou (2001*) ukazuje na negativan utjecaj kretanja cijena nafte na realni rast grčke ekonomije (kao i stopu zaposlenosti). Analizirajući VAR metodologijom europska gospodarstva[36] (1960:Q1-1999:Q4), *Cuñado i Pérez de Gracia (2003)* ističu pozitivan utjecaj cijena nafte na inflaciju, kao i negativan utjecaj na industrijsku proizvodnju, pri čemu konstatiraju da je efekt utjecaja cijena nafte veći kada se u obzir uzmu cijene denominirane u nacionalnim valutama. Funkcije impulsnog odziva analiziranih gospodarstava pokazuju iznimne varijacije u jačini, značaju a ponekad i u smjeru utjecaja cijena nafte, dok se sličnosti pronalaze ponajviše u *timingu*; negativni su efekti maksimalni oko 6 kvartala nakon naftnog šoka, a oporavak uslijedi do najdalje 10 do 12 kvartala. Autori navode i nepostojanje dugoročne međuovisnosti cijena energije i ekonomske aktivnosti, implicirajući značaj utjecaja cijena nafte samo u kratkom roku.

Miguel et al. (2003) dinamičkim stohastičkim modelom opće ravnoteže[37] analiziraju slučaj Španjolske (1970:Q1-1998:Q4) zaključujući da cijene nafte pojašnjavaju više od polovine agregatnih fluktuacija u dotičnom gospodarstvu, a i više u periodima njihova dramatičnijeg rasta. Koristeći istu metodologiju na proširenom uzorku europskih gospodarstava, isti autori (*Miguel et al., 2005*) navode da je monetarna politika odigrala važnu ulogu u jakim europskim gospodarstvima (Francuske, Ujedinjenog Kraljevstva, Nizozemske, Belgije, Luksemburga, Njemačke), posebno u naftnim šokovima sedamdesetih godina prošlog stoljeća, što za posljedicu ima manje oscilacije BDP-a u tim gospodarstvima u odnosu na ostale države iz uzorka, posebno Portugal, Španjolsku, Grčku, i Italiju. Autori naglašavaju ranjivost uvozno ovisnih ekonomija prilikom suočavanja s porastom cijena nafte, kao i činjenicu da su naftni šokovi imali negativan utjecaj na standard stanovništva, posebno u južnoeuropskim zemljama (iz uzorka) čije su vlade na porast cijena nafte reagirale lošom poreznom politikom.

[35] SAD, Kanadu, Japan, Njemačku (zapadnu), Francusku i UK, s iznimkom Norveške koja je neto izvoznik nafte (1967:Q3-1992:Q4)

[36] Njemačka, Belgija, Austrija, Španjolska, Finska, Francuska, Irska, Italija, Luksemburg, UK, Nizozemska, Danska, Grčka i Švedska.

[37] DSGE model – engl. **D**ynamic **S**tochastic **G**eneral **E**quilibrium model

Analizirajući VAR metodologijom zemlje OECD-a[38] (1972:Q3-2001:Q4), *Jimenez-Rodriguez i Sanchez (2005)* konstatiraju statistički značajan asimetričan utjecaj cijena nafte na rast realnog BDP-a, pri čemu prednost daju nelinearnim pokazateljima cijena nafte. Važno je naglasiti da u kratkom roku kod svih zemalja uvoznica nafte dobivaju statistički značajan negativan utjecaj, osim kod Japana kod kojeg je reakcija realnog rasta na rast realnih cijena nafte pozitivna. Većina reakcija realnog BDP-a na promjene cijena nafte odvija se unutar prva 3-4 tromjesečja, pri čemu je akumulirani negativni efekt najizraženiji u SAD-u (3,2% na 100%tni rast realnih cijena nafte, odnosno u rasponu 4%-6% na 100%tni rast nelinearnih pokazatelja cijena nafte) i istodobno dvostruko veći u odnosu na ostale OECD zemlje uvoznice nafte. Značajan dio dekompozicije varijance realnog BDP-a autori pripisuju upravo varijacijama cijena nafte, a važno je naznačiti i da je za euro zonu najveći udio varijacija cijena nafte u pojašnjavanju dekompozicije varijance inflacije u odnosu na pojedinačno zemlje iz uzorka.

Istražujući 12 europskih ekonomija (1970:Q1-2003:Q4), *Lardic i Mignon (2006)* zaključuju da realni gospodarski rast asimetrično reagira na cijene nafte (što nije dokazivo klasičnim testovima kointegracije). S druge strane, *Ran i Voon (2012)* zaključuju, na uzorku malih otvorenih azijskih zemalja (Hong Kong, Singapur, Južna Koreja i Tajvan; 1984:Q1-2007:Q3), kako cijene nafte uopće ne utječu na realni BDP, iako uočavaju utjecaj na nezaposlenost i inflaciju.

Istražujući efekte naftnih šokova strukturnim modelom opće ravnoteže[39], *Dybczak et al. (2008)* navode kako utjecaj cijena nafte na češko gospodarstvo nije dramatičan unatoč rastu cijena nafte u periodu od 2000. do 2007. Njihovi rezultati pokazuju kako rast cijena nafte od 20% (iskazan u češkim krunama) rezultira padom realnog BDP-a za 1,5% u kratkom[40], odnosno 0,8% u dugom roku, dok reakciju inflacije procjenjuju na +0,4 postotna poena godišnje u kratkom roku.

[38] SAD, UK, Japak, Kanada, Francuska, Italija, Njemačka, Norveška, euro zona.
[39] Engl. **C**omputable **G**eneral **E**quilibrium (CGE) model
[40] Pri čemu se kratkoročna stopa realnog rast smanjuje za 0,3 postotna poena.

Naslanjajući se na pristup *Kiliana (2009),* analizirajući globalnim VAR modelom s nametnutim restrikcijama 50 zemalja neto uvoznica[41] i izvoznica nafte[42] (1979:Q2–2011:Q2), *Cashin et al. (2014)* identificiraju naftne šokove s izvorom na strani ponude i potražnje. Njihovi rezultati impliciraju da je uzrok naftnog šoka ključan u determiniranju makroekonomskih posljedica naftnog šoka (ne samo za uvoznice već i za izvoznice nafte). Šok na strani ponude podrazumijeva pad ponude nafte i povlačenje krivulje ponude nafte u lijevo, čime se ravnoteža na tržištu uspostavlja pri višoj cijeni i nižoj količini. Kao primjer ovakvog šoka *Kilian (2009)* ističe šokove čiji su izvor poremećaji u količinama proizvodnje kao, primjerice, posljedica geopolitičkih tenzija na Srednjem Istoku. Šok na strani potražnje vođen snažnom globalnom ekonomskom aktivnošću podrazumijeva pomak krivulje potražnje u desno čime se uspostavlja tržišna ravnoteža uz višu cijenu i količinu. Primjer je recimo snažna potražnja azijskih rastućih ekonomija. Konkretnije, razlika u makroekonomskim efektima naftnog šoka na zemlje izvoznice i uvoznice nafte javlja se jedino kada je izvor naftnog šoka na strani ponude nafte. U tom slučaju realni rast uvoznica reagira negativno, a izvoznica pozitivno na naftni šok. S druge pak strane, makroekonomske reakcije na naftni šok koji je posljedica snažne globalne potražnje jednake su kod uvoznica i izvoznica nafte; kratkoročan rast realnog outputa popraćen inflacijskim pritiscima. Uvažavajući različite prirode naftnih šokova (kao i kod *Kilian, 2009* i *Cashin et al., 2014*), *Cunado et al. (2015)* analiziraju azijske uvoznike nafte (Japan, Indija, Koreja, Indonezija; 1997:Q2–2014:Q3) tvrdeći da naftni šokovi s uzrokom na strani ponude imaju ograničen negativan, a naftni šokovi uzrokovani snažnom globalnom potražnjom statistički značajan pozitivan utjecaj na rast analiziranih gospodarstava. Do gotovo istovjetnih zaključaka za Kinu (1992:Q1-2015:Q3) dolaze i *Cross i Nguyen (2017),* ali dodaju i da je učinak cijena nafte na realni rast u Kini kratkoročan i relativno skroman.

Procjenjujući u periodu od 1970. do 2010. utjecaj naftnih šokova na 144 gospodarstava (kategorizirana u četiri skupine: neto izvoznici nafte, OECD neto uvoznice nafte, neto uvoznice srednje razine dohotka i neto uvoznice niske razine dohotka), *Rasmussen i Roitman (2011)* zaključuju da se cijene nafte i BPD kreću u istom smjeru te da je navedena pozitivna veza sve snažnija prema koncu analiziranog perioda. Iako ističu (skromne) negativne efekte naftnih

[41] Kina, Japan, SAD, Euro zona (Austrija, Belgija, Finska, Francuska, Njemačka, Italija, Nizozemska, Španjolska), Argentina, Brazil, Čile, Peru, Južna Koreja, Malezija, Filipini, Singapur, Tajland, Australija, Indija, Novi Zeland, Južnoafrička Republika, Švedska, Švicarska, Turska, Egipat, Jordan, Mauritanija, Maroko, Sirija, Tunis

[42] Alžir, Ekvador, Bahrein, Kuvajt, Oman, Katar, Saudijska Arabija, Ujedinjeni Arapski Emirati, Indonezija, Iran, Libija, Nigerija, Venezuela, Kanada, Meksiko, Norveška i Ujedinjeno Kraljevstvo

šokova za pojedine zemlje (zbog čega nikako ne preporučaju generalizaciju zaključaka) navode da se isti generalno javljaju s vremenskim odmakom od oko četiri tromjesečja (na tragu istovjetnih zaključaka primjerice *Hamiltona (2005) i Jimenez-Rodriguez (2004*)) te da je, u prosjeku, kod većine zemalja naftni šok (rast cijena nafte) popraćen i rastom BDP-a u kratkom roku (iako skromnim za OECD). Konačno, ali ne manje važno, naglašavaju kako se većina zaključaka generalizira temeljem istraživanja na SAD-u koja pokazuju puno manji stupanj povezanosti rasta BDP-a i cijena nafte (najniži među zemljama OECD-a). Autori navedeno pravdaju puno nižim stopama poreza na naftne derivate u SAD-u, kao i višom energetskom intenzivnošću. Ujedno, autori stavljaju naglasak na udio nafte u ukupnom uvozu kao značajnu odrednicu jačine utjecaja naftnog šoka na pojedino gospodarstvo.

Gómez-Loscos et al. (2012) istražujući utjecaj naftnih šokova na realni rast i inflaciju unutar grupacije G7[43] (1970-2008) zaključuju da je njihova veza u promatranom periodu nelinearna. Prema navedenim autorima, utjecaj cijena nafte na inflaciju je oslabio do konca 1990ih (u odnosu na 1970e) da bi isti ponovno ojačao u 2000ima. Istovremeno navode da ne pronalaze robustnu vezu između cijena nafte i realnog BDP-a u promatranim gospodarstvima, iako navode slabljenje navedene veze u 1990ima.

Narayan et al. (2014) su, analizirajući 28 razvijenih i 17 zemalja u razvoju (uključujući Hrvatsku)[44], dokazali da se u slučaju 37 zemalja (21 razvijena i 16 zemalja u razvoju) temeljem cijena nafte mogu predviđati buduće stope realnog rasta kao i da je utjecaj cijena nafte na gospodarski rast negativan i statistički značajan (vrijedi i za Hrvatsku).

Cavallo i Ribba (2017) procjenjuju učinak naftnih šokova, kao i šokova monetarne politike euro zone, na poslovne cikluse odabranih gospodarstava srednje istočne Europe[45] izvan euro zone (1999:Q1-2015:Q4), uključujući i Hrvatsku[46]. Osim što konstatiraju visoku stopu usklađenosti poslovnih ciklusa Češke i Litve s onim u euro zoni, autori zaključuju da rast cijena nafte pozitivno utječe na cijene zemalja iz uzorka, te, istovremeno, negativno na njihove realne

[43] SAD, Kanada, Japan, Njemačka, Italija, Francuska i Ujedinjeno Kraljevstvo
[44] Period analize je, generalno, 1983:Q2-2011:Q2, s blažim odstupanjima kod pojedinih gospodarstva poput hrvatskog kod kojeg je analiza izvršena za period 1998:Q2-2011:Q2.
[45] Bugarska, Hrvatska, Češka, Litva, Poljska, Rumunjska
[46] Države CEE područja su Bugarska, Češka, Estonija, Hrvatska, Latvija, Litva, Mađarska, Poljska, Rumunjska, Slovačka i Slovenija.

outpute (s izuzetkom Litve[47]). Tako navode da 10%tni rast cijena nafte rezultira padom hrvatskog BDP-a za 0,95% (nakon 12 tromjesečja). Nadalje, autori navode da varijabilnost nacionalnog outputa u kratkom roku ponajviše pojašnjavaju interni strukturni šokovi, dok u dugom roku, kod svih analiziranih gospodarstva, naftni šokovi pojašnjavaju najveći dio varijabilnosti nacionalnog outputa (zajedno sa šokovima monetarne politike u euro zoni pojašnjavaju preko 70% varijacija BDP-a).

Evidentno je da se, kako navodi i *Lamazoshvili (2014),* utjecaj cijena nafte na gospodarski rast može promatrati iz tri različita kuta, uzimajući u obzir uzrok naftnog šoka, transmisijski mehanizam naftnog šoka kao i energetsku strukturu gospodarstva. Kako je već ranije istaknuto, prvenstveno *Kilian (2009)* stavlja naglasak na uzrok naftnog šoka tvrdeći (i dokazujući) da su efekti istih različiti ovisno o izvoru šoka. Nadalje, transmisija samog šoka, odnosno njegova apsorpcija može biti na strani ponude (kao proizvodni trošak) i/ili potražnje (smanjenje raspoloživog dohotka i utjecaj na investicije). Konačno, u obzir se može uzeti i energetska struktura gospodarstva (proizvodnje ali i potrošnje) koja se razlikuje od gospodarstva do gospodarstva, ali i mijenja kroz vrijeme (tako su, primjerice, razvijena gospodarstva sve više energetski efikasna), a također može utjecati na način kako gospodarstvo apsorbira naftni šok.

Na koncu, ali ne manje važno, nužno je istaknuti i poprilično zanemaren aspekt ili, u odnosu na netom izneseno, četvrti kut promatranja utjecaja cijena nafte na gospodarski rast, a riječ je o ulozi očekivanja. Naslanjajući se na zaključke prethodnih istraživanja o slabljenju utjecaja naftnih šokova na realno gospodarstvo (*Hooker, 1996, 2002; Blanchard i Galí, 2007; De Gregorio et al., 2007; Herrera i Pesavento, 2009*)[48], *Milani (2009)* sugerira da ekonomski agenti, iskustveno učeći o proteklim gospodarskim kretanjima i njihovim posljedicama, prilagođavaju svoja očekivanja o gospodarskim kretanjima. Kako očekivanja imaju značajan utjecaj na makroekonomska kretanja, učinak naftnog šoka na gospodarstvo može biti značajno promijenjen ako isti uzrokuje značajne prilagodbe očekivanja ekonomskih agenata. Autor tako navodi da su unutar analiziranog perioda (SAD, 1960:Q1-2008:Q1) naftni šokovi imali snažniji utjecaj na output i inflaciju 1970ih u odnosu na 2008. Snažnije reakcije outputa i inflacije u prvom dijelu uzorka nisu rezultat reakcija monetarne politike (čijim se mjerama može pripisati oko 20% ukupnog učinka naftnog šoka), već razvoja efekta očekivanja (kao posljedice procesa

[47] Što autori pojašnjavaju činjenicom da se u Litvi nalazi velika rafinerija nafte.
[48] Što poneki autori pokušavaju pojasniti tvrdeći da je veza cijena nafte i realnog gospodarstva nelinearna (*cf. Hamilton, 2003; Kilian i Vigfusson, 2011*).

učenja) zbog čega su koncem analiziranog perioda efekti naftnog šoka skromniji. Jednako tako *Baumeister i Kilian (2016)* ističu kako potpuno iste promjene cijena nafte mogu polučiti razlike u očekivanjima od strane kućanstava, donositelja politike, aktera na financijskim tržištima i ostalih, ovisno o tome na koji način svaki od njih formira očekivanja. Ovakva je perspektiva izuzetno važna s aspekta razumijevanja i modeliranja transmisijskih kanala naftnih šokova.

Brojnost prikazanih istraživanja (iako ista čine tek fragment ukupnog broja), kao i razlike u njihovim zaključcima, dodatno potenciraju važnost istraživanja utjecaja cijena nafte na makroekonomske pokazatelje na razini pojedinog gospodarstva jer, jednako kao što se pojedine politike ne mogu samo „preslikati" iz jednog gospodarstva u drugo, isto vrijedi i s načinom kako svako od njih apsorbira naftni šok.

2.2.2. Kretanje inflacije u odnosu na promjene cijena nafte

Cijene sirovina, jer se iste koriste kao inputi u proizvodnom procesu, pozitivno utječu na agregatnu razinu cijena (*Bloch et al., 2006*). Istom se analogijom promatraju i cijene nafte u kontekstu njihovog utjecaja na inflaciju. Naftni se derivati koriste kako direktno (ponajviše u sektoru transporta), tako i indirektno kao proizvodni inputi u proizvodnji čitavog niza proizvoda i usluga. Tom se analogijom i eventualni utjecaj cijena nafte na inflaciju odvija u dvije etape (*Žikov et al., 2019*). U prvoj rundi efekata promjene cijena nafte se najbrže odražavaju na inflaciju kroz utjecaj na cijene naftnih derivata koje neposredno kupuju krajnji potrošači, a snaga ovog utjecaja ovisi o zastupljenosti izdataka za naftne derivate u ukupnim troškovima. U drugoj se rundi, nešto sporije, prelijeva utjecaj promjene cijena nafte na krajnje cijene proizvoda i usluga u čijoj je proizvodnji i/ili transportu neophodna uporaba naftnih derivata. U obzir bi se svakako trebao uzeti i udio troškova naftnih derivata u transportu dobara odnosno proizvodnim troškovima. *Álvarez et al. (2011)* dodaju ovome i treću dimenziju tvrdeći da, prethodno spomenutu, drugu rundu efekata karakterizira i pomak u očekivanoj inflaciji (kao posljedica bihevioralnih prilagodbi potrošača, odnosno radnika i tvrtki) koji se naknadno pretače i u promjenu stvarne inflacije[49]. Isti autori naglašavaju i važnost utjecaja cijena nafte ne samo na razinu, već i na varijabilnost inflacije.

[49] Autori su analizirajući sva tri navedena efekta za Španjolsku i euro područje (1997:Q1–2007:Q4) zaključili kako je direktan utjecaj cijena nafte na inflaciju dobio na važnosti zbog rasta potražnje za naftnim derivatima u odnosu na preostala dva efekta koji su gotovo iščezli.

Istraživanja utjecaja cijena nafte na inflaciju nerijetko su posljedica istraživanja djelovanja monetarne ekonomije na naftne šokove. Razlog fokusiranja na reakcije monetarnih vlasti na pojavu naftnih šokova leži u činjenici da su se, nakon što bi se dokazao negativan efekt naftnih šokova na realnu ekonomiju, istraživali i mehanizmi kojima se promjene cijena nafte pretaču na realnu ekonomiju. Od svih makroekonomskih pokazatelja, upravo bi inflacija trebala najbrže reagirati na promjene cijena nafte.

Utjecaj cijena nafte na inflaciju ovisi i o načinu na koji reagira monetarna politika na naftni šok. Stoga ni ne čudi da su najintenzivnije reakcije inflacije na naftne šokove bile one iz 1970ih (*Sek et al., 2015*), a što je monetarnim vlastima bio „prvi susret" s naftnim šokovima. Snažan utjecaj cijena nafte na inflaciju po prvi puta je detektiran 1970ih kada se gospodarstvo SAD-a našlo u stagflaciji, a što je ozbiljno narušilo postavke Phillipsove krivulje koja je u to vrijeme predstavljala temeljni vid modelske specifikacije kretanja inflacije (*Globan et al., 2014*).

Rezultati niza istraživanja ukazuju na značajan utjecaj cijena nafte na inflaciju. Među prvim istraživanjima relacije cijena nafte i inflacije može se istaknuti ono *Pierce i Enzlera (1974).* Autori navode da rast cijena nafte vodi porastu potražnje za novcem, pri čemu nemogućnost i/ili nesposobnost monetarnih vlasti da poprate povećanu potražnju za novcem rastom njegove ponude, vodi povećanju kamatnih stopa (što smanjuje potrošnju i investicije i usporava gospodarski rast). Jedna od najcitiranijih studija na tu temu je i ona *Bernanke, Gertler i Watson-a (1997*, u daljnjem tekstu BGW) koja tvrdi kako da bi se negativni efekti naftnih šokova mogli izbjeći uz trošak povišene stope inflacije. Za razliku od *Hamiltona (1983)*, *BGW (1997)*, kao i *Pierce i Enzler (1974)* pripisuju gospodarske recesije, koje su uslijedile nakon naftnih šokova, upravo restriktivnom djelovanju monetarne politike. Pored navedenih niz je ranijih istraživanja (u SAD-u) ustanovio značajan utjecaj cijena nafte na inflaciju (*cf. Hamilton, 1983, 1988, 1996, 2000; Tatom, 1988; Mork, 1989; Mork et al., 1994; Kahn i Hampton, 1990; Hooker, 1996, 1999a,b; Huntington, 1998*).

Koristeći iste podatke kao *BGW (1997)*[50], *Hamilton i Herrera (2004)* dolaze do dijametralno suprotnih zaključaka ističući da monetarna politika ima ograničen i gotovo neznatan utjecaj na ublažavanje realnih posljedica naftnih šokova. Autori navode da naftni šokovi imaju znatno jači direktan efekt na realnu ekonomiju tvrdeći da jednostavno nije moguće mjerama monetarne

[50] Ali duže vremenske odmake od *BGW (1997)*

politike anulirati negativne efekte naftnih šokova. Također smatraju da bi porast inflacije koji sugeriraju *BGW (1997)* trebao biti previsok kako bi se ublažio efekt porasta cijena nafte. Također, *Davis i Haltiwagner (2001)* tvrde da kanal monetarne politike nema snagu neutralizacije ukupnih negativnih efekata naftnih šokova. Na istom tragu, *Balke, Brown i Yücel (2002)*, koji su revidirali rezultate BGW studije, u konačnici zaključuju da čak i kada se izolira utjecaj monetarne politike, i dalje postoji značajan utjecaj naftnih šokova na BDP, kao i asimetričan odgovor BDP-a i kamatnih stopa na promjene cijena nafte. Slijedom ovih zaključaka, autori istražuju i kanal kamatnih stopa kao mogući kanal transmisije efekata promjena cijena nafte na gospodarstvo, te zaključuju da se utjecaj naftnih šokova na ekonomiju rasprostire upravo posredstvom mehanizma kamatne stope. *Cunado i Perez de Gracia (2003),* za period od 1960. do 1999. godine, pronalaze značajan utjecaj cijena nafte na inflaciju na uzorku EU gospodarstava[51], kao i u kasnijem istraživanju na uzorku 6 azijskih ekonomija za period od 1975. do 2002. godine (*Cunado i Perez de Gracia, 2005*).

U periodu od 1980. do 2001. godine, procjenjujući Phillipsovu krivulju (za SAD, Ujedinjeno Kraljevstvo, Francusku, Njemačku i Japan), *LeBlanc i Chinn (2004)* pronalaze da rast cijena nafte od 10% vodi direktnim proinflacijskim pritiscima u rasponu od 0,1 do 0,8 postotnih poena kao i da nema statistički značajne razlike u utjecaju cijena nafte na inflaciju u SAD-u i razvijenim EU ekonomijama. *Chen (2009)*, analizirajući uzorak 19 industrijaliziranih zemalja, zaključuje da se uslijed jednako snažnog rasta cijena nafte inflacija povećava za, otprilike, 0,05 postotnih poena (s vremenskim odmakom od jednog tromjesečja). *Álvarez et al. (2011)* zaključuju da 10%-tni rast cijena nafte u prosjeku povećava inflaciju za 0,2 postotna poena u euro zoni i Španjolskoj. Istraživanje ESB-a (*ESB, Monthly Bulletin, October, 2013, str. 61.*) navodi da u euro području 10%-tni rast cijena nafte povećava inflaciju za 0,5 postotnih poena.

Istražujući uzroke različitih reakcija inflacije na promjene cijena nafte među gospodarstvima, *Gelos i Ustyugova (2017)* na uzorku od 31 razvijene i 61 zemlje u razvoju[52] (2001-2010) dolaze do sljedećih zaključaka. Inflacija zemalja s izraženijom energetskom intenzivnošću je podložnija naftnim energetskim šokovima. Autori smatraju da pojedino gospodarstvo može u određenoj mjeri amortizirati negativne efekte naftnog šoka prvenstveno kroz reduciranje očekivane inflacije i utjecaj na drugu rundu efekata naftnog šoka i to boljom fiskalnom

[51] Belgija, Austrija, Španjolska, Finska, Francuska, Irska, Italija, Luksemburg, Portugal, Ujedinjeno Kraljevstvo, Nizozemska, Danska, Grčka i Švedska.
[52] Uključujući i Hrvatsku.

politikom, ali i većim stupnjem monetarne autonomije kao i u nešto manjoj mjeri monetarnom politikom ciljane inflacije. Nadalje, navode da je za uspjeh u amortiziranju samih šokova iznimno važno povjerenje građana u institucije. Konačno, zaključuju kako je efekt prelijevanja cijena nafte na inflaciju izraženiji u periodima iznadprosječnih razina inflacije.

Među novijim sveobuhvatnijim istraživanjima može se istaknuti i ono *Choi et al. (2018)* koji su panel metodologijom istraživali utjecaj fluktuacija svjetskih cijena nafte na inflaciju na uzorku od 72 razvijena gospodarstva i gospodarstva u razvoju (1970-2015). Autori zaključuju da globalni rast cijena nafte od 10% u prosjeku povećava inflaciju za 0,4 postotna poena pri čemu ovaj utjecaj, za kojeg tvrde da je veoma sličan kod razvijenih i zemalja u razvoju, u potpunosti iščezava dvije godine nakon šoka. Pored navedenog, autori ističu i da je navedeni utjecaj asimetričan, pri čemu pozitivni naftni šokovi imaju snažniji utjecaj na razinu inflacije od negativnih. Ipak, konstatiraju da je utjecaj cijena nafte na inflaciju oslabio kroz vrijeme što pripisuju prvenstveno vođenju primjerenije monetarne politike. U istom istraživanju, korištenjem mjesečnih podataka, autori analiziraju i noviji period od 2000. do 2015. godine te zaključuju da su varijacije u rezultatima među zemljama obuhvaćenim uzorkom ponajviše posljedica udjela troškova za transport u potrošačkoj košarici.

Promjene u prirodi odnosa između cijena nafte i inflacije privukle su pažnju niza znanstvenika. Tako *Blanchard i Gali (2007)* ističu da se snažnija veza cijena nafte i inflacije prije 1980ih (u SAD-u) može dovesti u vezu s niskim realnim rastom, visokom nezaposlenošću i visokom inflacijom. Kasnijom stabilizacijom inflacije i rasta BDP-a, veza cijena nafte i inflacije slabi unatoč skokovitim epizodama rasta cijena nafte u 1990ima. Isti autori, kao moguće pojašnjenje smanjene osjetljivosti inflacije na cijene nafte, navode i rigidnost realnih nadnica, povećanu vjerodostojnost monetarne politike kao i pad udjela nafte u potrošnji energije. Od ostalih se pojašnjenja može navesti i ono *Peersmana (2009)* koji konstatira da se priroda naftnih šokova kroz vrijeme mijenja te da je cjenovna elastičnost potražnje za naftom s protokom vremena sve niža. *Álvarez et al (2011)* navedenom pridodaju i veću energetsku efikasnost (odnosno, nižu energetsku intenzivnost) proizvodnih procesa, što se može dovesti u vezu s težnjom o sve manjoj ovisnosti o relativno oskudnom energentu, odnosno supstitucijom istoga gdje je to moguće i/ili troškovno prihvatljivo.

Hooker (2002) je proučavajući odnos između cijena nafte i inflacije u SAD-u (1962. - 1980. i 1981.-2000.) zaključio da su cijene nafte do 1980ih imale značajan utjecaj na temeljnu inflaciju

i nikakav ili vrlo slab utjecaj na istu u periodu koji slijedi. *Chen (2009)*, pak, tvrdi da je odnos cijena nafte i inflacije (za analiziranih 19 industrijaliziranih gospodarstava), gotovo bez iznimke, znatno slabiji u odnosu na 1970e. *Evans i Fisher (2011)* u svom istraživanju ne pronalaze dokaze o prelijevanju cijena nafte na temeljnu inflaciju[53] u SAD-u[54] od polovine 1980ih nadalje, a njihove su rezultate potvrdili i *Chen i Wen (2011)*. *Valcarcel i Wohar (2013),* analizirajući prelijevanje cijena nafte u inflaciju u SAD-u u periodu od 1948. do 2011. godine, tvrde da je utjecaj cijena nafte na inflaciju zanemariv.

Uvažavajući prirodu, točnije izvor naftnog šoka, *Cashin et al. (2014)* zaključuju da šokovi na strani ponude nafte rezultiraju rastom proizvodnih troškova što djeluje proinflatorno. S druge strane, šokovi na strani potražnje za naftom rezultiraju tek privremenim utjecajem na inflaciju. Uz navedeno, *De Gregorio et al. (2007),* na istom tragu navode i da bi inflacija trebala različito reagirati na naftne šokove ovisno o tome smatraju li se isti kratkotrajnima ili dugotrajnima. Tako smatraju da je prelijevanje cijena nafte u inflaciju bilo slabije sredinom 2000ih jer se smatralo da je tadašnji rast cijena nafte samo privremen, a ne dugotrajan kao što se u konačnici ispostavilo (kao posljedica snažne globalne potražnje za naftom).

Posttranzicijska gospodarstva su u većoj mjeri energetski intenzivna u odnosu na razvijena gospodarstva. Zbog toga je za očekivati i veći utjecaj cijena energije, samim time i nafte, na inflaciju. U skladu s navedenim *Stavrev (2009)* i *Égert (2011)* su analizirali udio energetske potrošnje u CPI-u i zaključili da nove zemlje članice EU troše od 40 do 100% više energije u odnosu na EU15. Na tragu navedenog je i zaključak *Petrović et al. (2011)* da se, kako se odvijala transformacija od socijalističkih ka tržišnim gospodarstvima, utjecaj pojedinih elemenata na inflaciju u tranzicijskim gospodarstvima[55] značajno promijenio. Tako navode da su, za razliku od 1990ih, ključni generatori inflacijskih kretanja u spomenutim gospodarstvima šokovi na strani ponude, primarno cijene hrane i nafte, kao i deficit platne bilance i devizni tečaj, s druge strane.

[53] Inflacija koja isključuje cijene hrane i energenata
[54] Istraživanje je provedeno za dva vremenska perioda: 1959:Q1-1979:Q2 i 1982:Q3-2008:Q4
[55] Analizirana tranzicijska gospodarstva uključuju: Albaniju, Bugarsku, Hrvatsku, Češku, Estoniju, Mađarsku, Latviju, Litvu, Makedoniju, Poljsku, Rumunjsku, Rusiju, Srbiju, Slovačku, Sloveniju i Ukrajinu (1991:Q1-2008:Q4)

U najnovijem istraživanju *Živkov et al. (2019),* korištenjem Markovljevog switching modela, istražuju utjecaj cijena nafte na inflaciju u 11 srednjoistočnih EU gospodarstava[56] uključujući i Hrvatsku (1996:M01-2018:M06) te zaključuju da je utjecaj cijena nafte na inflaciju relativno skroman: rast cijena nafte od 100% rezultira rastom inflacije u rasponu od 1 do 6 postotnih poena. Najizraženiji je utjecaj cijena nafte na inflaciju u većini zemalja u dugom roku što implicira izraženiju drugu rundu efekata rasta cijena nafte. Važno je naglasiti kako sami autori ističu da su, unatoč zastupljenosti ovakvog tipa istraživanja u akademskim krugovima, istraživanja utjecaja cijena nafte na inflaciju na navedenoj grupaciji zemalja (i zemljama u razvoju; *Choi et al., 2018*) iznimno rijetka.

U današnje vrijeme naftni šokovi više nisu novost; monetarna politika im se prilagođava, a i njen je kredibilitet značajno veći. Kako se čini, monetarna politika može, barem do neke mjere, utjecati na način na koji će se efekt povećanja cijene nafte odraziti na pojedino gospodarstvo, pogotovo ako vodi politiku ciljane inflacije. *Bodenstein et al. (2012)* ističu da adekvatna reakcija monetarne politike na naftni šok uvelike ovisi o prirodi, odnosno uzroku, naftnog šoka. Jedino u čemu se gotovo svi autori slažu je činjenica da naftni šokovi, u svakom slučaju, povećavaju mogućnost grešaka u određivanju adekvatnih i pravodobnih mjera monetarne politike. Kako ističe *Chen (2009),* iako ne postoji znanstveni konsenzus oko utjecaja cijena nafte na gospodarstvo posredstvom monetarne politike, može se reći da se cijene nafte barem djelomično pretaču u inflaciju kako u razvijenim tako i u zemljama u razvoju zbog čega je monetarnim vlastima koje ju nastoje kontrolirati u interesu što bolje razumjeti prirodu i jačinu navedenog utjecaja.

Cijene nafte bi se svakako trebale uzeti u obzir prilikom modeliranja inflacije općenito, pa tako i Hrvatskoj. Ovome valja dodati i navode o mogućem asimetričnom utjecaju cijena nafte na inflaciju koji se klasičnim simetričnim modelima zanemaruje u potpunosti (*Mork, 1989; Hamilton, 2009, 2011; Herrera, 2001; Valcarcel i Wohar, 2013; Salisu et al., 2017*).

2.2.3. Mehanizmi utjecaja cijena nafte na nezaposlenost

Pitanje nezaposlenosti jedno je od ključnih ekonomskih, ali i socijalnih izazova s kojim se dan danas suočavaju nositelji politike kako u zemljama u razvoju, tako i u razvijenim zemljama. U

[56] Analizirana gospodarstva uključuju: Bugarsku, Hrvatsku, Češku, Estoniju, Mađarsku, Latviju, Litvu, Poljsku, Rumunjsku, Slovačku i Sloveniju.

pravilu su stope nezaposlenosti niže u razvijenim ekonomijama u odnosu na iste u zemljama u razvoju (*Rafiq et al, 2009*), što može biti posljedica kako politika usmjerenih na rast zaposlenosti, s jedne, tako i snažnije potrošnje (i dohotka po stanovniku) i bolje raspoloživosti proizvodnih resursa, s druge strane (*Fields, 2011*). Literatura o utjecaju cijena nafte na makroekonomske pokazatelje razvijala se na različite načine i obuhvaćala različite kanale. Jedan od njih je i utjecaj cijena nafte na nezaposlenost (i/ili zaposlenost) kojem, prema *Acurio-Vásconez* (*2015a*), još uvijek nije dan adekvatan značaj.

Grafički prikaz (Vidjeti Grafikon 2.2.3.1.) utjecaja cijena nafte na krivulju potražnje za radom može se pronaći kod *Gärtner (2009, str. 435*) koji, da bi pojasnio navedeni utjecaj, uvodi naftu kao proizvodni input u standardni oblik Cobb-Douglasove proizvodne funkcije koju definira kao:

$$Y=K^{\alpha}OIL^{\beta}L^{1-\alpha-\beta} \qquad (2.11.)$$

Ovako definirana proizvodna funkcija promatra potražnju za radom kao funkciju količine kapitala i nafte u proizvodnom procesu. Dok su promjene količine kapitala u kratkom i srednjem roku relativno spore, situacija je puno fleksibilnija kad je riječ o količinama nafte pri čemu će tvrtke angažirati dodatnu jedinicu nafte sve dok se trošak (cijena) iste ne izjednači s graničnom proizvodnošću nafte. Početna situacija prikazana je točkom A na a) i b) dijelu Grafikona 2.3.3.1.. Uslijed rasta cijena nafte sa p_A^{NAFTA} na p_B^{NAFTA} inicijalna reakcija krivulje potražnje za naftom je pomak iste iz pozicije B u poziciju B'.

Grafikon 2.2.3.1.: Utjecaj porasta cijena nafte na krivulju potražnje za radom

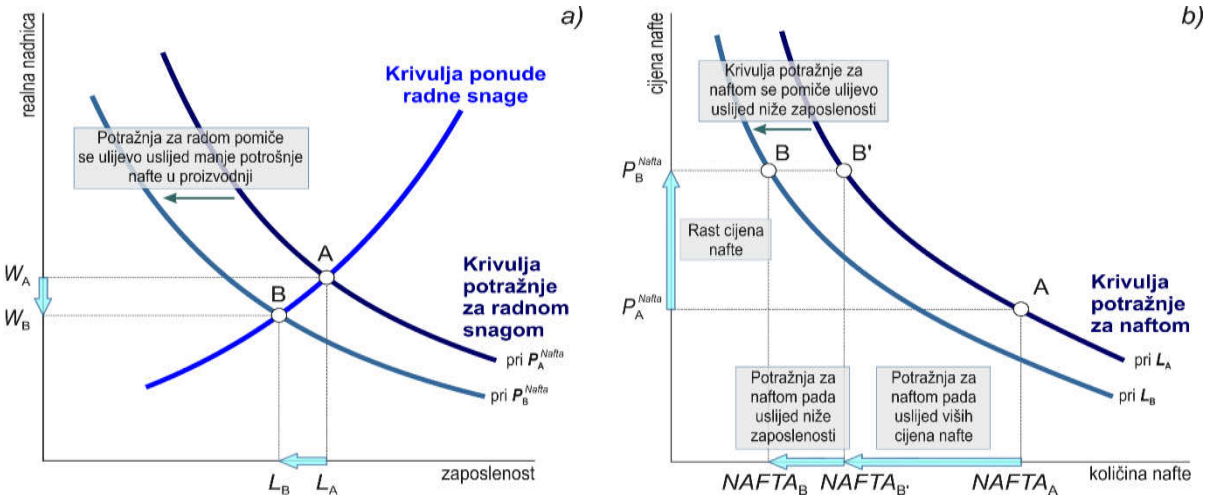

Izvor: Obrada autorice prema *Gärtner, 2009*, str. 435.

Uslijed rasta cijena nafte, tvrtke uočavaju da je granična proizvodnost nafte ispod njenog troška (cijene) na što reagiraju smanjenjem potražnje za naftom sve dok se ponovno navedene veličine ne izjednače. Kako navedeno ima reperkusije i na potražnju za radom, ovdje nije kraj promjenama. Naime, u kombinaciji s manjom količinom nafte i nepromijenjenom količinom kapitala, granična produktivnost rada opada na svim razinama zaposlenosti što za posljedicu ima smanjenje potražnje za radnom snagom. Ali ovo nije kraj priče jer smanjena potražnja za radnom snagom dodatno umanjuje potražnju za naftom što ponovno smanjuje potražnju za radom itd. Kad se pojašnjeni efekt s vremenom zaustavi, nove krivulje potražnje za naftom (pri L_B) kao i potražnje za radom (pri p_B^{NAFTA}) biti će u poziciji lijevo od početne. Nova ravnotežna točka na tržištu rada uspostaviti će se na nižoj razini zaposlenosti i pri nižim realnim nadnicama.

Temeljem prethodno navedene Cobb-Douglasove proizvodne funkcije može se derivirati krivulja potražnje za radom (u odnosu na L) čime se dobiva granična proizvodnost rada odnosno realna nadnica (w):

$$\frac{dY}{dL} = (1 \quad \alpha \quad \beta)\frac{K^{\alpha}OIL^{\beta}}{L^{\alpha+\beta}} = w \tag{2.12.}$$

Istom logikom nacionalna krivulja potražnje za radom može se izvesti deriviranjem funkcije (2.1.) u odnosu na cijenu nafte (OIL) kako bi se dobila granična produktivnost nafte s ciljem izjednačavanja iste s njenom cijenom:

$$\frac{dY}{dOIL} = \beta\frac{K^{\alpha}L^{1-\alpha-\beta}}{OIL^{1-\beta}} = p^{OIL} \tag{2.13.}$$

Obje izvedene krivulje su međusobno neovisne. Kako bi se iznjedrila funkcija potražnje za radom (u ovisnosti o cijenama nafte) rješava se funkcija (2.3.) i rezultat se interpolira u funkciju (2.1.) te se u konačnici dobije kratkoročna/srednjoročna funkcija potražnje za radom oblika:

$$w = (1 \quad \alpha \quad \beta)\left(\frac{K}{L}\right)^{\frac{\alpha}{1-\beta}}\left(\frac{\beta}{p^{OIL}}\right)^{\frac{\beta}{1-\beta}} \tag{2.14.}$$

Prema istoj, uslijed rasta cijena nafte, krivulja potražnje za radom (koja je zakrivljena, nije linearna) pomiče se ulijevo (prema dolje).Odgovor (ne)zaposlenosti na rast cijena nafte ovisi dakle, o nagibu izvedene krivulje, kao i o rigidnosti realnih nadnica.

Acurio-Vásconez (*2015b*) ističe pak nisku stopu supstitucije nafte ostalim proizvodnim inputima zbog čega tvrtke uslijed rasta cijena nafte, da bi podržale troškove proizvodnje nepromijenjenima, ne umanjuju potražnju za istom već za preostalim proizvodnim inputima, pa tako i radom. Navedeno povećava nezaposlenost odnosno reducira otvaranje novih radnih mjesta. Autorica ističe i da se isti troškovni efekt može postići snižavanjem realnih nadnica, ali radnici po naftnom šoku također traže realna povećanja nadnica zbog povećanih troškova njihove potrošnje. Tvrtke tako radije pristaju na povećanu potražnju za radnim satima od strane postojeće radne snage, na uštrb novih zapošljavanja.

U svom pionirskom radu, *Hamilton (1983)* navodi negativnu korelaciju između cijena nafte i budućih (naknadnih) razina nezaposlenosti. Uključujući naknadno i period do 1988. (Q:2) *Mork (1989)* donosi istovjetan zaključak. U kasnijem radu *Hamilton (1988),* kroz modelsku provjeru međuodnosa nezaposlenosti i poslovnih ciklusa u SAD-u, konstatira da bi naftni šokovi mogli biti izvor fluktuacija agregatne razine nezaposlenosti kao i realnog outputa. *Uri (1996)* i *Uri i Boyd (1996)* također konstatiraju signifikantan utjecaj cijena nafte na nezaposlenost u SAD-u (1980-1994). *Ewing i Thompson (2007)* također navode signifikantnu korelaciju cijena nafte i nezaposlenosti u SAD-u, dok nešto kasnijom studijom (*Ewing i Yang, 2009*) na dezagregiranim podacima također konstatiraju statistički značajnu negativnu vezu zaposlenosti i cijena nafte u proizvodnim i neproizvodnim sektorima diljem država SAD-a (1990-2005).

Promatrajući naftni šok kao porast troškova na strani ponude, rast cijena nafte će, zbog rasta proizvodnih troškova, umanjiti razinu proizvodnje, a posljedično i količinu rada koja je angažirana u proizvodnom procesu. Kao posljedica pada produktivnosti raste i razina nezaposlenosti (*Loungani, 1986; Brown i Yucel, 2002*). Pojašnjenje za navedeno smanjenje razine zaposlenosti, odnosno porast razine nezaposlenosti daje ranije definiran model klasičnog šoka na strani ponude. Za očekivati je da će jačina utjecaja cijena nafte na zaposlenost i nezaposlenost ovisiti i o udjelu troškova nafte u proizvodnom procesu, kao i o stupnju komplementarnosti rada i nafte kao proizvodnih inputa. *Ferderer (1996)* ističe kako agregatna nezaposlenost raste kada relativni cjenovni šokovi postanu volatilniji, što implicira da volatilnost cijena nafte osnažuje poremećaje u sektorskim prilagodbama na tržištu rada, vodeći većoj nezaposlenosti.

Koristeći VAR metodologiju, *Davis i Haltiwanger (2001)* su izučavali utjecaj naftnih šokova na kreaciju i destrukciju radnih mjesta u prerađivačkoj industriji SAD-a (1972-1988) te navode

da naftni šokovi pojašnjavaju 20%-25% varijabilnosti stope rasta zaposlenosti. Zaključak studije je ujedno i da stopa rasta nezaposlenosti asimetrično reagira na promjene cijena nafte. Autori konstatiraju kako zaposlenost reagira negativno na poraste cijena nafte jer uslijed rasta cijena nafte agregatni i alokativni mehanizmi djeluju u istom smjeru, dok u obratnoj situaciji spomenuti mehanizmi djeluju u suprotnim smjerovima anulirajući moguće pozitivne efekte na razinu zaposlenosti.

Brown i Yucel (2002) nadalje navode da će, uz prisutnost rigidnosti nadnica, pad BDP-a induciran rastom cijena nafte uzrokovati rast nezaposlenosti i daljnji pad razine BDP-a. Ako je smanjenje produktivnost rada veće od smanjenja realnih plaća, tvrtke će otpuštati radnike što povećava nezaposlenost i gubitke realnog BDP-a. Zbog otpornosti na smanjenje realnih plaća (rigidnost nadnica), porast cijena nafte dovodi do zahtjeva za rastom nominalnih plaća. U kratkom roku, pritisak na plaće, zajedno sa smanjenom potražnjom, vodi većoj nezaposlenosti.

Carruth et al. (1998) su razvili model efikasnosti nadnice[57] te zaključuju kako svega dvije varijable, cijena nafte kao i realna kamatna stopa, pojašnjavaju glavninu poslijeratnih kretanja stope nezaposlenosti u SAD-u (1954:Q2-1995:Q2). U naknadnoj provjeri rezultata *Carruth et al. (1998)*, rezultati *Andreopoulosa (2009)* impliciraju da realna cijena nafte pomaže u pojašnjavanju kretanja nezaposlenosti SAD-a samo u periodima recesije, dok istu važnost u periodima realnog gospodarskog rasta ima realna kamatna stopa (period analize: 1953:Q2-2007:Q2). Na model efikasnosti nadnice (*Carruth et al., 1998)* modelski se naslanja i istraživanje *Doğrul i Soytas (2010)* o međuodnosu cijena nafte, realnih kamatnih stopa i nezaposlenosti u Turskoj (2005:M01 - 2009:M08). Njihovi rezultati su istovjetni zaključcima *Carruth et al. (1998)* za SAD, pri čemu ističu da je tematika utjecaja cijena nafte na nezaposlenost izvan grupacije razvijenih zemalja nedovoljno istražena.

Teorija efikasnosti nadnice (*engl. the efficiency wage theory*) kreće od pretpostavke o pozitivnoj korelaciji efikasnosti, odnosno produktivnosti, rada i više plaće (nadnice). Slijedom navedenog, tvrtke će nuditi više plaće kako bi privukle produktivnije radnike koji će svojom povećanom

---

[57] Teorija efikasnosti nadnice (*engl. efficiency wage theory*) kreće od pretpostavke o pozitivnoj korelaciji efikasnosti, odnosno produktivnosti, rada i više plaće (nadnice). Slijedom navedenog, tvrtke će nuditi više plaće kako bi privukle produktivnije radnike koji će svojom povećanom produktivnošću tvrtki više nego kompenzirati povećani trošak rada. Dok god dodatni profit (koji proizlazi i veće produktivnosti rada) prelazi dodatne troškove, poslodavci će povećavati nadnicu. Nužan je, dakle, brži rast produktivnosti od rasta plaća. Posljedično, dio radne snage ostaje nezaposlen.

produktivnošću tvrtki više nego kompenzirati povećani trošak rada. Dok god dodatni profit (koji proizlazi i veće produktivnosti rada) prelazi dodatne troškove, poslodavci će povećavati nadnicu. Nužan je, dakle, brži rast produktivnosti od rasta plaća. Posljedično, dio radne snage ostaje nezaposlen. Tzv. "nadnica efikasnosti" može znatno premašiti ravnotežnu nadnicu i izazvati nezaposlenost koja se ne može spriječiti spremnošću nezaposlenih na prihvaćanje niže nadnice (*Mrnjavac, 2011*). Takozvani model zabušavanja (*engl. the shirking model*) je najpopularniji teorijski model unutar literature o efikasnosti nadnice. Temeljna ideja modela zabušavanja je sljedeća: kako poslodavci ne mogu nadgledati zaposlene bez nastanka dodatnih troškova, posloprimcima nude više plaće (više od razine koja bi „očistila“ tržište) kako bi povećali njihovu produktivnost te kako bi demotivirali radnike od zabušavanja (*Calvo, 1979; Shapiro i Stiglitz, 1984*). *Shapiro i Stiglitz (1984)* tvrde da tvrtke pristaju na isplatu viših plaća spram dodatnog troška nadziranja radnika jer radnici smatraju trošak zabušavanja većim od njegove koristi. Ključan faktor koji determinira utjecaj zabušavanja je razina nezaposlenosti. Što je razina nezaposlenosti viša i, još važnije, što je potencijalna nezaposlenost dugotrajnija, radnici će biti produktivniji, jer je trošak detekcije zabušavanja time veći (uslijed otkaza, radnik dugo vremena neće biti u mogućnosti naći posao). Vrijedi i obrnuto. Na ovom je mjestu iznimno važno istaknuti i utjecaj minimalne nadnice (plaće) kao i ulogu sindikata čije djelovanje rezultira plaćama iznad onoga što bi bila njihova tržišna razina, a ni približno ne utječu na rast produktivnosti rada (ako uopće).

Na tragu prethodno iznesenog su i zaključci istraživanja *Keane i Prasada (1996)* koji konstatiraju kako porast cijena nafte u prosjeku smanjuje realne plaće svih zaposlenih (na agregatnoj razini), ali povećava realne plaće sposobnijih/produktivnijih radnika (*engl. skilled workers*). Mogućnost zapošljavanja produktivnijih radnika raste usporedno s rastom cijena nafte sugerirajući da je produktivan radnik i više nego adekvatna zamjena za poskupjeli energent. Autori navode da je u kratkom roku utjecaj cijena naftne na zaposlenost negativan dok u dugom roku vrijedi suprotno, što pripisuju supstituciji proizvodnih inputa cjenovno/troškovno efikasnijima.

U konačnici valja istaknuti da, uz iznimku istraživanja *Carruth et al. (1998) i Doğrul* i *Soytas (2010)* modeli efikasnosti nadnice uglavnom ignoriraju energiju kao proizvodni input. *Beaudreau (2005)* pak tvrdi da je uvažavanje energije kao primarnog proizvodnog inputa, s inženjerskog stajališta, nužno jer nikakav rad nije moguć bez energije.

Pad zaposlenosti, uz pretpostavku nepostojanja rigidnosti nadnica, može značiti i nuđenje nižih nadnica (i pristajanje radnika na iste), što umanjuje kupovnu moć radnika. Što je naftni šok dugotrajniji, rast nezaposlenosti (i/ili smanjenje nadnica) u većoj mjeri umanjuje kupovnu moć stanovnika, što dalje može (zbog smanjene potražnje za širom paletom roba i usluga) dodatno potencirati pad ukupne proizvodnje i daljnji rast nezaposlenosti. Ovaj se efekt očituje kroz utjecaj cijena nafte na potrošnju i investicije, odnosno rezultat je utjecaja cijena nafte na potražnu stranu. Uslijed naftnog šoka, s obzirom da investicije determiniraju potencijalne proizvodne kapacitete u dugom roku, povećane cijene inputa (zbog rasta cijena nafte) umanjuju investicije, a time i output (*Doğrul i Soytas, 2010*). Kapital, koji je ključan proizvodni input, ima tendenciju „bježanja" prema gospodarstvima koja će ga bolje oploditi; stoga, investitori uslijed naftnih šokova premještaju sredstva u gospodarstva s višim stopama rasta od onoga koje trpi značajnije negativne posljedice naftnog šoka (*Ahmad, 2013*).

Hamilton (1988) ističe utjecaj cijena nafte na potrošnju (potražnju) dobara za čije je korištenje nužna uporaba energije jer su u tom slučaju nafta i promatrana dobra komplementi. Smanjena potražnja za navedenim dobrima uzrokuje kako cikličku, tako i strukturnu nezaposlenost, a efekt se potencijalno multiplicira ovisno o povezanosti dotičnih sektora proizvodnje s ostalim sektorima čiji su proizvodi i usluge angažirani u proizvodnom procesu. *Jones, Leiby i Paik (2004)* također ističu utjecaj cijena nafte na strukturu potražnje, mehanizam koji se u konačnici odražava na razinu nezaposlenosti, ali mu utjecaj kreće kroz poremećaje sektorski specifične potražnje. Prema autorima studije, potražnja za trajnim dobrima (ponajviše automobilima) posebice je pogođena u vremenima recesija jer potrošači (zbog oslabljene kupovne moći) preusmjeravaju potražnju na potrošna dobra (hrana, odjeća, obuća). Na taj način stradavaju sektori, odnosno industrije koje proizvode trajna dobra, što u konačnici znači otpuštanje radne snage u tim sektorima. Najbolji primjer je situacija u autoindustriji koja je uvijek snažno pogođena jakim pozitivnim naftnim šokovima.

Na tragu navedenog je i tzv. hipoteza sektorske realokacije, od energetski intenzivnih ka energetski efikasnim sektorima. Tako *Loungani (1986)* tvrdi da naftni šokovi u SAD-u vode realokaciji radne snage, što smanjuje stopu zaposlenosti. *Lee, Ni i Ratti (1995)* razmatraju sektorske realokacije kao moguće objašnjenje za dobivenu statističku neznačajnost promjene stope zaposlenosti prilikom pada cijena nafte. Kada cijene nafte padnu, sektorska realokacija radne snage ima negativne efekte na zaposlenost koji poništavaju pozitivne efekte makroekonomskog šoka (pozitivnog) na strani ponude. Autori uvode i efekt iznenađenja u

analizu, tvrdeći da neočekivanost promjene cijena nafte ima puno jači utjecaj na razinu zaposlenosti od same promjene cijena nafte. *Lardic i Mignon (*2005) navode opasnost dugoročnog porasta cijena nafte koji potiče promjene u proizvodnoj strukturi utječuči posljedično i na rast stope nezaposlenosti. Rast cijena nafte umanjuje profitabilnost naftno-intenzivnih sektora i potiče tvrtke na usvajanje energetski učinkovitijih tehnologija što, na tragu *Lounganij*evih *(1986)* konstatacija, potiče sektorske realokacije radne snage (ka energetski učinkovitijim sektorima).

Ovome valja dodati i potencijalni utjecaj monetarne politike na naftni šok, odnosno reakciju iste, o čemu je već i bilo riječi u prethodnom poglavlju o utjecaju cijena nafte na inflaciju. Suočene s proinflatornim pritiscima povećanih cijena nafte, monetarne vlasti pribjegavaju instrumentima restriktivne monetarne politike kako bi suzbili nekontrolirani rast inflacije. Niže stope inflacije nerijetko idu na štetu realnih stopa gospodarskog rasta kao i rasta stope nezaposlenosti, što je posebno izraženo u gospodarstvima u kojima monetarne vlasti provode politiku ciljane inflacije (*Tang et al., 2010*).

U nastavku su navedeni zaključci poznatijih studija van SAD-a (s izuzetkom studije *Doğrul i Soytas, 2010*, o kojoj je ranije bilo riječi). *Papapetrou (2001), Robalo i Salvado (2008)* i *Ahmad (2013)* pronalaze statistički značajnu vezu između cijena nafte i nezaposlenosti u, redoslijedno, Grčkoj, Portugalu i Pakistanu. *Ahmad (2013)* pored navedenog zaključuje da ne postoji statistički značajna veza između nezaposlenosti i realne kamatne stope. *Chang i Wong (2003)* dolaze do vrlo sličnog zaključka i u slučaju Singapura (1978-2000) ipak naznačavajući da je utjecaj cijena nafte na nazaposlenost, iako statistički značajan, marginalan i vidljiv tek s vremenskim odmakom od 5 tromjesečja nakon naftnog šoka.

Značajan utjecaj rasta cijena nafte na rast nezaposlenosti u Njemačkoj, korištenjem VAR metodologije na mjesečnim podacima u dva perioda analize (1973-2008 i 1990-2008; nakon ujedinjenja istočne i zapadne Njemačke), dokazuju i *Löschel i Oberndorfer (2009)*. Zanimljivo je naglasiti da su autori koristili tri različita pokazatelja cijena nafte[58] (prema: *Hamilton, 1983; Mork, 1989; Hamilton, 1996*), uvažavajući mogućnost asimetrije i efekta iznenađenja, te zaključuju (iako je dokazan negativan utjecaj cijena nafte na razinu nezaposlenosti neovisno o

[58] Realna cijena nafte, MORK+, MORK-, NOPI.

korištenom pokazatelju) da je adekvatniji pokazatelj koji uvažava asimetriju kao i efekt iznenađenja (spram linearnih pokazatelja). Iako je njemačko gospodarstvo povećalo energetsku efikasnost u novijem razdoblju, cijene nafte, kako navode autori, makroekonomska kretanja kao i kretanja na tržištu rada su i dalje u velikoj mjeri ovisna o situaciji na globalnom naftnom tržištu. Ovime autori negiraju učestale navode prethodnih istraživanja prema kojima je utjecaj cijena nafte na gospodarstvo oslabio koncem 1980ih. Nadalje, kao pojašnjenje rezultata naslanjaju se na tumačenje *Jones et al. (2004)* koji asimetriju u prijenosu naftnih šokova pripisuju skupoći realokacije proizvodnih resursa.

Ispitujući utjecaj cijena nafte na BDP, inflaciju i nezaposlenost u 17 azijskih zemalja (1980-2010, s prilagodbama duljina vremenskog niza kod pojedinih zemalja), *Chang et al. (2011)* zaključuju da je utjecaj cijena nafte na nezaposlenost prisutan samo kod razvijenih zemalja (Australije, Novog Zelanda, Singapura, Južne Koreje i Tajvana) i to u dugom roku, dok kod preostalih članica navedenog odnosa nema. Također je važno naznačiti da je i kod prvotne grupacije zemalja uočeni utjecaj izrazito skroman te se odvija s vremenskim odmakom od četiri do pet tromjesečja.

Cuestas i Gil-Alana (2018) istražuju utjecaj cijena nafte na odabrana CEE[59] gospodarstva[60] te započinju analizu s 2000. godinom (2000:Q1-2015:Q4) kako bi izbjegli periode visokih stopa nezaposlenosti iz 1990ih koji su produkt prvenstveno strukturnih promjena navedenih gospodarstva, kao i tranzicije u tržišne ekonomije (*Sorm i Terrell, 2000; Haltiwanger i Vodopivec, 2002; 2003*). Autori ukazuju na nepostojanje kratkoročnog utjecaja cijena nafte na nezaposlenost, ali također navode postojanje utjecaja cijena nafte na prirodnu stopu nezaposlenosti u dugom roku. Kako je njihovom studijom, između ostalog, uvažena pretpostavka asimetričnog utjecaja cijena nafte na prirodnu stopu nezaposlenosti, autori nadalje zaključuju kako se prirodna stopa nezaposlenosti i cijene nafte kreću u istom smjeru, odnosno kako ne postoji asimetrija. Ovaj zaključak je u skladu s konstatacijom *Druant et al. (2012)* koji navode da europski poslodavci pokazuju određen stupanj rigidnosti prilikom prilagođavanja plaća/nadnica promjenama cijena nafte.

[59] *Engl. Central East Europe* – srednje istočna Europa
[60] Češka, Estonija, Mađarska, Latvija, Litva, Poljska, Slovenija i Slovačka.

Kako je problem nezaposlenosti u Hrvatskoj prilično izražen, što je detaljnije prikazano poglavljem *3.3. Analiza kretanja nezaposlenosti*, svakako bi trebalo uzeti u obzir i cijene nafte kao mogući eksplanatorni kanal uslijed modeliranja kretanja nezaposlenosti.

2.2.4. Utjecaj cijena nafte na kretanje osobne potrošnje

Počevši od *Hamiltonovog (1983)* pionirskog istraživanja, intenzivno se proučava utjecaj cijena nafte na gospodarstvo, pri čemu je razina akademske produktivnosti definirane tematike uglavnom pozitivno korelirana s (pozitivnim) naftnim šokovima. Ipak, velika većina postojećih istraživanja primarno je fokusirana na realni gospodarski rast, odnosno način na koji promjene cijena nafte utječu na isti. *Lee i Ni (2002)* navode kako tvrtke u SAD-u primarno percipiraju naftne šokove kao udar na potražnju za njihovim proizvodima, a ne kao udar na troškove proizvodnje. Iako je nekolicina navedenih istraživanja razmatrala potencijalni utjecaj cijena nafte na gospodarstvo i s potražne strane, *Mehra i Petersen (2005)* su među prvima istraživali utjecaj naftnih šokova na osobnu potrošnju stanovništva, odnosno utjecaj naftnih šokova na potražnu stranu. Na tragu navedenog *Hamilton (2008)* ističe da je ključni mehanizam utjecaja cijena nafte na gospodarstvo upravo na strani potražnje, pri čemu naftni cjenovni šok uzrokuje poremećaj u veličini i/ili strukturi potrošnje i kućanstava i poduzeća. Iako je prisutan izražen fokus medija i politike na ovu tematiku, još uvijek se malo zna o jačini ovog efekta, o utjecaju na realnu potrošnju, kao i samim promjenama u potrošnji koje se javljaju kao odgovor na fluktuacije u cijenama nafte (*Edelstein i Kilian, 2009; Wang, 2013*).

Bhattacharyya (2011) i *Broadstock et al. (2014)* navode kako naftni šokovi imaju potencijal utjecaja na osobnu potrošnju direktno i indirektno. Direktan je onaj dio utjecaja koji uglavnom proizlazi iz čovjekove potrebe za kretanjem, odnosno putovanjima prometnim sredstvima na pogon naftnim derivatima (automobili, autobusi, zrakoplovi i sl.) te podrazumijeva neposrednu potražnju za naftnim derivatima. Naftni šok, koji se vrlo brzo pretače u cijene naftnih derivata, povećava i troškove proizvodnje svih dobara i usluga u čijoj su proizvodnji isti nužni, troškove prijevoza kao i troškove svih dobara i/ili usluga u čijoj je konzumaciji prijevoz nužan[61].

[61] Ovaj je aspekt potencijalno interesantan iz perspektive RH kao turističke destinacije kojoj prihodi od turizma predstavljaju važan dio BDP-a a u koju čak 90% turista dolazi na odmor korištenjem cestovnog prometa (*Šolman, 2010*).

Indirektan se efekt može manifestirati na dva načina. Prvi se očituje kroz proinflatorne efekte naftnih šokova kao i efekte na realni dohodak. Porast cijena nafte dovodi do rasta inflacije (*Bernanke et al., 1997*), što može rezultirati uvođenjem restriktivnih mjera od strane monetarnih vlasti. Posljedica navedenog je negativna stopa rasta BDP-a koja može utjecati i na pad raspoloživog dohotka, odnosno osobne potrošnje. Ako rast nominalnih plaća ne prati rast inflacije, realni se dohodak smanjuje, a posljedično, zbog djelovanja efekta dohotka, i potrošnja jer povećanje cijena nafte ostavlja manje sredstava za potrošnju na ostala dobra. Uloga monetarne politike u ovom je procesu također iznimno važna; monetarne vlasti koje često ciljaju niske stope inflacije mogu restriktivnim mjerama još u većoj mjeri (od samog rasta cijena nafte) smanjiti realne stope rasta gospodarstva. Uslijed rasta cijena nafte kao i neizvjesnosti glede njihova budućeg kretanja, raste i štednja nauštrb potrošnje. S rastom vjerojatnosti gubitka zaposlenja (kao posljedice naftnog šoka) raste i granična sklonost štednji spram granične sklonosti potrošnji (*Edelstein i Kilian, 2009*).

Drugi vid rasprostiranja indirektnog efekta naftnih šokova na osobnu potrošnju je supstitucijski efekt uslijed rasta cijena nafte. Efekt supstitucije u izravnoj potrošnji naftnih derivata je izraženiji u dugom roku (i pozitivno koreliran s rastom cijena nafte), a osim o vremenu prilagodbe na promjenu cijena ovisi i o mogućnostima supstitucije nafte drugim energentima. Koliko će sam efekt porasta cijena nafte biti jak, ovisi i o elastičnosti potražnje za naftnim derivatima; što je elastičnost manja, efekt je snažniji, i obratno. Kako rastu cijene nafte, kućanstva odgađaju ili se u potpunosti suzdržavaju od kupnje trajnih potrošnih dobara (*Bernanke, 1983; Pindyck, 1991*), posebno onih čije funkcioniranje zahtijeva uporabu energije/naftnih derivata (iz tog razloga u ovu skupinu ponajprije spadaju automobili; *Hamilton, 1988*). Na istom tragu, *Herrera et al. (2019)* ističu kako upravo potražnja za motornim vozilima (primarno automobilima) igra ključnu ulogu u pojašnjavanju kontrakcija osobne potrošnje uslijed rasta cijena nafte.

Dio literature ističe i promjene uzoraka potrošnje pod utjecajem povećane neizvjesnosti, što uzrokuje alokativne poremećaje, odnosno sektorske pomake od energetski intenzivnih ka energetski efikasnim sektorima *(Davis, 1987; Hamilton, 2008).* Slične realokacije su moguće i unutar samog sektora ako kupci preferiraju energetski efikasnije proizvode *(Hamilton, 1988; Bresnahan i Ramey, 1993).* Nadalje, cijene nafte utječu i na odluku o stanovanju, o izvorima grijanja kućanstva, stupnju izolacije stambenog prostora, ali i udaljenosti do radnog mjesta koja može utjecati i na odluku o preseljenju. Općenito, indirektni efekti bi mogli biti čak i izraženiji

od direktnih, ali tek u srednjem ili dugom roku (*Davis i Haltiwanger, 2001; Lee i Ni, 2002)*. Neke od njih je, s obzirom na navedeno, i jako teško modelski „uhvatiti“.

Istraživanja koja ispituju utjecaj cijena nafte na potrošnju (kućanstva i osobnu potrošnju općenito) prilično su rijetka (*Odusami, 2010*; *Wang, 2013*), što je prilično začuđujuće s obzirom na važan utjecaj potrošnje na realni rast i udio osobne potrošnje u BDP-u. Pri tome je važno istaknuti i da niz istraživanja koji se osvrću na utjecaj naftnih šokova na potražnju (osobnu potrošnju), posebno starijih, uglavnom nude zaključke o navedenom odnosu na razini teorije, bez konkretnijih empirijskih provjera.

Utjecaj naftnih šokova na potrošnju tek je relativno nedavno došao u fokus relativno skromnog broja istraživanja (*Mehra i Petersen, 2005; Odusami, 2010; Wang, 2013*). U navedenim je radovima osobna potrošnja modelirana korištenjem hipoteze permanentnog dohotka, koncepta koji je nakon inicijalnog uvođenja od strane *Friedmana (1956)* postao uobičajena platforma makroekonomista za istraživanje determinanti osobne potrošnje. Hipoteza permanentnog dohotka pojašnjava da je osobna potrošnja determinirana tekućim dohotkom i bogatstvom kao i očekivanom (diskontiranom) vrijednošću budućih dohodaka (primitaka). U skladu s navedenim, potrošačke odluke su pod utjecajem očekivanih, odnosno permanentnih budućih dohodaka. Konkretno, prema hipotezi permanentnog dohotka, samo porast veličine permanentnog dohotka utječe na veličinu i strukturu potrošnje za razliku od tekućeg, raspoloživog dohotka čije povećanje rezultira porastom štednje, a ne potrošnje. U „idealnoj situaciji“ osobna će potrošnja biti determinirana optimalnim, odnosno ravnotežnim odnosom osobne potrošnje i permanentnog dohotka. U stvarnosti se unutar pojedinih vremenskih perioda (mjesec, tromjesečje, godina) nerijetko događaju nepredvidive situacije koje uzrokuju odstupanje osobne potrošnje od, kako ga nazivaju *Campbell i Mankiw (1989)* i *Mehra i Petersen (2005)*, planiranog dohotka. Na tragu navedenog, i *Kilian (2008a)* navodi da je uslijed naftnog šoka pad potražnje za dobrima moguće i posljedica porasta sklonosti štednji kao mjere predostrožnosti uslijed promjenjivosti cijena i rezultirajuće neizvjesnosti.

Mehra i Petersen (2005) percipiraju naftne šokove kao izvor kratkoročnih odstupanja potrošnje od planirane razine, a ne kao izvor fundamentalnih odstupanja realizirane od planirane veličine potrošnje. Autori zaključuju da je veza između cijena nafte i osobne potrošnje u SAD-u asimetrična i nelinearna (1962:Q1 - 2004:Q2), pri čemu rast cijena nafte ima negativan efekt na cijene nafte, dok pozitivan utjecaj na potrošnju u slučaju pada cijena nafte izostaje. Pored

navedenog, *Mehra i Petersen (2005)* također navode da naftni šok značajnije utječe na pad potrošnje kada je neočekivan, odnosno kada uslijedi nakon dužeg perioda relativno stabilnih cijena. *Odusami (2010)* dolazi do vrlo sličnih zaključaka te se slaže da je osobna potrošnja pod utjecajem naftnih šokova i to na način da rezultira promjenom omjera osobne potrošnje i bogatstva. *Edelstein i Kilian (2009)* ne nalaze dokaze asimetrije, ali se slažu s *Mehra i Petersen (2005)* da cijene nafte statistički značajno utječu na potrošnju. Koristeći VAR metodologiju, autori identificiraju način na koji različite kategorije potrošnje reagiraju na naftne šokove te konstatiraju da rast cijena nafte od 1% rezultira padom osobne potrošnje za 0,15%, s odmakom od jedne godine. Analizirajući i strukturu potrošnje u SAD-u (1970:M01-2006:M07), *Edelstein i Kilian (2009)* pripisuju reakcije osobne potrošnje na promjene cijena nafte upravo potražnji za automobilima koja reagira četiri puta snažnije u odnosu na ostala trajna potrošna dobra, odnosno sedam puta snažnije u odnosu na potražnju za ostalim potrošnim dobrima i uslugama. Konačno, autori zaključuju da cijene nafte unatoč njihovu utjecaju na kretanje osobne potrošnje nipošto nisu ključna determinanta kretanja iste.

Naslanjajući se na zaključke *Lettau i Ludvigson (2001)* koji su ustanovili da osobna potrošnja, bogatstvo i dohodak od rada u SAD-u dijele zajednički trend u dugom roku, ali da u kratkom dolazi do značajnih odstupanja od navedenog dugoročnog trenda, *Odusami (2010)* zaključuje da se odstupanja navedenog odnosa u kratkom roku mogu pojasniti upravo promjenama cijena nafte (SAD, 1959:Q2-2007:Q4) pri čemu je snaga detektiranog odnosa sve slabija u novijoj povijesti. Istražujući odnos omjera potrošnje i bogatstva u odnosu na promjene cijena nafte, autor navodi da u periodima gospodarske ekspanzije, kada su promjene cijena nafte skromne, rast (pad) cijena nafte utječe na smanjenje (povećanje) potrošnje kućanstava, kao i da je utjecaj cijena nafte na potrošnju asimetričan. Rast cijena nafte također, prema navodima *Odusami (2010)*, vodi većoj potrošnji agregatnog bogatstva kućanstava u početnom stadiju recesije ako je istoj prethodio značajan rast cijena nafte. Ipak, autor u konačnici zaključuje da su u posljednjim desetljećima (nakon 1980ih) američka kućanstva, u smislu potrošnje, znatno otpornija na naftne šokove, odnosno da reakcije monetarnih vlasti na nafte šokove vrlo malo ili nikako ne utječu na omjer potrošnje i bogatstva američkih kućanstava. Također ističe da je statistički značajan utjecaj cijena nafte na potrošnju evidentan samo uslijed rasta cijena nafte koji je iznadprosječan. U protivnom (uslijed ispodprosječnog rasta cijena nafte) je utjecaj cijena nafte na potrošnju iznimno slab.

Baumeister, Peersman i Van Robays (2009) analiziraju utjecaj naftnih šokova na industrijalizirana gospodarstva SAD-a, Japana, Švicarske, euro zone (kao cjeline), Kanade, Norveške, Ujedinjenog Kraljevstva i Australije (1986:Q1-2008:Q1). Pridavanjem važnosti uzroku naftnih šokova, kao i inicijalno *Kilian (2009)*, također zaključuju da se priroda utjecaja naftnog šoka na gospodarstva razlikuje ovisno o o njegovom uzroku na istovjetnom tragu i *Kilianovih (2009)* zaključaka. Promatrajući reakciju osobne potrošnje na naftne šokove, autori konstatiraju kako je reakcija iste u Švicarskoj i zemljama euro zone potpuno drugačija od iste u SAD-u. Dok je reakcija osobne potrošnje u SAD-u, kao i realnog BDP-a, na naftni šok negativna i gotovo trenutna (pripisujući navedeno rastu sklonosti štednji), za razliku od euro zone gdje se osobna potrošnja prilagođava iznimno tromo što autori dovode u vezu s izraženo rigidnošću realnih nadnica. Ovakav rezultat autori nadalje pojašnjavaju i izraženijim indirektnim utjecajima naftnih šokova zbog čega su u euro zoni reakcije osobne potrošnje (ali i investicija) vidljive tek s odgodom zbog čega ih dovode u vezu s djelovanjem monetarne politike koja na naftni šok reagira korekcijom kamatnih stopa na više. Uočavanjem znatnih varijacija u smjeru i jačini utjecaja cijena nafte na analizirane makroekonomske pokazatelje odabranih zemalja, autori iste pripisuju nizu faktora, od smanjenja ovisnosti o nafti i kredibilnosti monetarne politike do različitih karakteristika tržišta rada.

Analizirajući navedenu tematiku unutar grupacije G7, *Wang (2013)* konstatira, kao i *Mehra i Petersen (2005)*, da je reakcija gospodarstava na promjene cijena nafte nelinearna i asimetrična, iako donekle različita među analiziranim gospodarstvima (2005:Q1 – 2010:Q2). Dok su cijene nafte ispod (modelom procijenjene) ravnotežne razine, rast cijena nafte rezultira odgodom potrošnje, točnije rast cijena nafte od 1% rezultira padom osobne potrošnje za 0,69%. Rast cijena nafte povećava cijene u gospodarstvu, kao i potražnju za novcem. Monetarne vlasti moraju kontrolirati rast inflacije te reagiraju povećanjem kamatnih stopa. U takvim uvjetima se potrošači radije odlučuju na štednju nego na potrošnju. Kada cijene nafte pređu ravnotežnu (modelom procijenjenu) razinu, rast cijena nafte od 1% rezultira rastom osobne potrošnje za 0,74%. Dramatičan i dugotrajan rast cijena nafte rezultira kontinuiranim rastom cijena proizvodnih inputa kao i, posljedično, dobara i usluga. Čak i kada je inicijalna reakcija potrošača (na rast cijena nafte) odgađanje potrošnje, oni će zbog rastućih cijena dobara i usluga biti prisiljeni povećati potrošnju. *Wang (2013)* razlikuje prirodu odnosa cijena nafte i osobne potrošnje ovisno o visini cijena nafte. Početnim rastom cijena nafte utjecaj na osobnu potrošnju je negativan. Ako pak cijene nafte prijeđu ravnotežnu (dugoročnu) razinu, njihovim se daljnjim rastom povećava potrošnja. *Wang (2013)* također detektira razlike u reakcijama gospodarstava

na naftne šokove koje pripisuje različitim načinima vođenja monetarne politike koja reagira na proinflatorne naftne šokove različitim mehanizmima, ali uvažava i specifičnosti pojedinih gospodarstava u vidu, primjerice, gospodarske strukture. Konačno, *Wang (2013)* ističe da se efekt naftnih šokova na osobnu potrošnju odvija sporo i postupno, što je prvenstveno posljedica niske cjenovne elastičnosti potražnje za naftnim derivatima kao i njihovim komplementima. Efekt na potrošnju izraženiji je kroz opći rast cijena kao i transfer bogatstva od zemalja uvoznica prema zemljama izvoznicama nafte što utječe na njihov ekonomski rast.

Alsalman i Karaki (2019) su istražili postojanje asimetrije u prilagodbi osobne potrošnje cijenama nafte u SAD-u (1973:M2-2015:M12) kao i razlike u reakcijama osobne potršnje na naften šokove ovisno o njihovom izvoru. Autori zaključuju kako je reakcija agregatne osobne potrošnje na naftni šoka na strani potražnje (vođen očekivanjima o budućim cijenama nafte) negativna i asimetrična (snažnija uslijed rasta cijena nafte nego njihova pada) kao i da je utjecaj naftnih šokova na strani ponude na osobnu potrošnju ograničen. Konačno, naftni šok na strani potražnje (kao posljedica snažne gospodarske aktivnosti) rezultira značajnim smanjenjem osobne potrošnje pri čemu je prilagodba osobne potrošnje na navedenu vrstu šoka puno sporija u odnosu na prilagodbu na naftni šok na strani potražnje koji je posljedica šok na strani potražnje vođenog očekivanjima o budućim cijenama nafte.

De Michelis, Ferreira i Iacoviello (2019), panel VAR metodom*,* analiziraju utjecaj cijena nafte na osobnu potrošnju (između ostalog) u SAD-u, odnosno američkim državama (1989-2018), kao i panelom kojim obuhvaćaju 55 zemalja svijeta (1975-2018). Njihovi zaključci upućuju na postojanje asimetrije implicirajući da, unatoč detektiranoj negativnoj vezi među promatranim varijablama, rast cijena nafte ima snažniji utjecaj na pad osobne potrošnje negoli pad cijena nafte na njen rast. Važno je ipak naznačiti i da njihovi zaključci impliciraju prilagodbu osobne potrošnje cijenama nafte koja se događa s vremenskim odmakom.

Literatura o utjecaju cijena nafte na osobnu potrošnju, iako skromna, gotovo je isključivo koncentrirana na SAD (*Herrera et al., 2019*). Pored upravo iznesenih zaključaka *Wangove (2013)* studije unutar G7 grupacije zemalja, u nastavku slijedi pregled ostalih internacionalnih studija.

Zhang (2014) analizira utjecaj cijena nafte na potrošnju kućanstava u Kini (2000:Q1 - 2012:Q3) i to na način da, nakon što potvrđuje negativan utjecaj cijena nafte na potrošnju u Kini, proučava

utjecaj cijena nafte na razini pojedine skupine potrošnih dobara. Autor konstatira da su zaključci istraživanja utjecaja naftnih šokova na potrošnju na agregatnoj razini prilično nejasni što pojašnjava logičnom činjenicom da nisu sva dobra koja se u gospodarstvu konzumiraju u jednakoj mjeri povezana s cijenama nafte. *Zhang*ovi *(2014)* rezultati ukazuju na značajan i brz utjecaj cijena nafte na potražnju u sektoru transporta (u prvom tromjesečju), kao i na postojanje asimetrije u smislu izraženijih negativnih efekata rasta cijena nafte u odnosu na pozitivne efekte njihova pada.

Testirajući hipotezu permanentnog dohotka u zemljama ASEAN-a i istočne Azije[62] (1988:Q1-2012:Q4), *Zhang i Broadstock (2014)* donose zaključak o asimetričnom utjecaju cijena nafte u analiziranim gospodarstvima uz važnu napomenu o razlikama u jačini, a u pojedinim slučajevima i smjeru, utjecaja među istima. Naglašavajući važnost nacionalnih specifičnosti analiziranih gospodarstava autori kao moguće pojašnjenje istoga navode razlike u životnim stilovima, socijalnim strukturama, društvenim političkim uređenjima, energetskim strukturama, razinama gospodarske razvijenosti, obrazovnoj strukturi i sl. U skladu s navedenim, potrošnja kućanstava potencijalno se znatno razlikuje među različitim ekonomijama. Čak i kada je korištena tehnologija na strani potrošnje energije među različitim ekonomijama usporediva, razlike u životnim stilovima polučiti će i različite efekte na kretanje i strukturu osobne potrošnje. Evidentno, ni po pitanju utjecaja cijena nafte na potrošnju ne postoji znanstveni konsenzus, što nameće potrebu za daljnjim istraživanjima.

Konačno se mogu navesti i zaključci *Bokan et al. (2018)* koji su u ime ESB-a proveli analizu utjecaja cijena nafte na osobnu potrošnju u euro zoni. Naslanjajući se na uvodnu konstataciju ovog poglavlja o direktom i indirektnom utjecaju cijena nafte na potrošnju, autori ističu kako kućanstva potroše/kupuju trećinu ukupne količine naftnih derivata direktno, dok se preostali dio naftnih derivata angažira u sektorima koji proizvode ostale ne energetske proizvode/usluge. Indirektan se efekt rasta cijena nafte rasprostire kroz utjecaj na proizvodne troškove navedenih sektora koji, ako nisu u mogućnosti prebaciti teret rasta proizvodnih troškova u cijelosti na krajnje potrošače, pribjegavaju smanjenju nadnica i/ili profita.

[62] Kina, Hong Kong, Indonezija, Japan, Malezija, Singapur, Južna Koreja, Tajvan i Tajland.

Nadalje, *Bokan et al. (2018)* navode kako promjene u relativnim cijenama uvoza i izvoza, odnosno u uvjetima razmjene, utječu na osobnu potrošnju, a potom ukazuju na evidentan utjecaj cijena nafte na uvjete razmjene u euro zoni (prema *Backus i Crucini, 2000,* isti je prisutan i globalno), što može biti jedan od mehanizama kako se u konačnici utjecaj cijena nafte pretače na osobnu potrošnju. Detektirani odnos kretanja cijena nafte i uvjeta razmjene u euro zoni ukazuje na inverzan odnos[63] prikazanih pokazatelja. On jasno ukazuje na narušavanje uvjeta razmjene kao posljedicu rasta cijena nafte uslijed čega dolazi do pada kupovne moći kućanstava. Vrijedi i obratno. Konačno, autori navode kako je odnos cijena nafte i uvjeta razmjene (u srednjem i dugom roku) podložan promjenama[64] koje u konačnici mogu utjecati i na promjenu utjecaja cijena nafte na potrošnju kućanstava.

S obzirom da osobna potrošnja čini preko polovine BDP-a, istraživanje utjecaja cijena nafte na realni gospodarski rast, svakako bi trebalo uvažiti i utjecaj cijena nafte na realnu osobnu potrošnju što je u ovom istraživanju i učinjeno.

2.2.5. Reakcije investicija na kretanje cijena nafte

Prema modelima ekonomskog rasta, investicije predstavljaju ključnu komponentu agregatne potražnje zbog doprinosa rastu kapitala i gospodarskom rastu (*Mankiw, 2006*). Investicije (posebno *greenfield* investicije) doprinose rastu potražnje i potrošnje kao i stope zaposlenosti, a rast investicija je, pored navedenog, i indikator pozitivnih očekivanja od strane investitora glede budućih gospodarskih kretanja. Ipak, unatoč akademskom konsenzusu oko nedvojbene važnosti investicija u gospodarstvu, razumijevanje determinanti investicija (pa i empirijski dokazi istih) na makroekonomskoj i mikroekonomskoj razini je još uvijek prilično ograničeno. Osim što predloženi modeli nisu adekvatno pojašnjavali kretanje investicija, proporcije varijacija varijabli koje se tradicionalno smatraju odgovornima za kretanje (varijacije) razine investicija, poput troška kapitala, u stvarnosti su nedostatne kako bi pojasnile značajan udio varijacije investicija (*Dixit i Pindyk, 1994; Chirinko, 1993*). Ovome značajno pridonosi i činjenica da su razlike u zastupljenosti investicija u gospodarstvu među različitim ekonomijama

[63] Odnos je uobičajeno negativan kod zemalja uvoznica, a pozitivan kod zemalja izvoznica nafte.
[64] Npr. promjene u stupnju energetske intenzivnosti/efikasnosti potrošnje i proizvodnje ne energetskih dobara/usluga

izrazito velike, što u novije vrijeme potiče znanstvenike na provjeru hipoteza o utjecaju dotada zanemarenih čimbenika[65].

Pindyck i Solimano (1993), kao i *Carruth et al. (2000),* navode sve veći fokus znanstvenika na utjecaj rizika, odnosno neizvjesnosti na investicije. Ovaj rizik dovode u direktnu vezu s nepovratnim troškovima[66] koji ne mogu biti nadoknađeni ako se ispostavi da će budući tržišni uvjeti biti gori od očekivanih (što umanjuje vrijednost očekivanih budućih prihoda). Također, i kod povratnih investicija[67] (*engl. reversible investment*) tvrtke uobičajeno raspolažu određenim vremenskim periodom unutar kojeg planiraju poduzeti investiciju (i angažirati vlastite proizvodne resurse). Ovaj tip investicija jako je osjetljiv na neizvjesnost glede očekivanih budućih prihoda. Na tragu navedenog *McDonald i Siegel (1986)* navode da uvjeti visoke neizvjesnosti, koji utječu na percepciju rizičnost glede budućih prihoda, imaju iznimno visok utjecaj na odluku o poduzimanju investicije, čak i veću od utjecaja visine kamatne stope na poduzimanje iste. S druge strane, mogu se navesti i pojedina istraživanja koja navode da je odnos neizvjesnosti i investicija dvojben. Tako *Goldberg (1993), Leahy i Whiteed (1996)* i *Driver et al. (1996)* navode slabu ili nikakvu vezu između neizvjesnosti i investicija prilikom ispitivanja utjecaja promjenjivosti; deviznog tečaja, povrata na prinos dionica i tržišnog udjela na investicije.

Upravo su se cijene nafte nametnule kao važan faktor u doprinosu neizvjesnom poslovnom okruženju s potencijalom još značajnijeg utjecaja u budućnosti (*Henriques i Sadorsky, 2011*). Utjecaj cijena nafte na investicije posljedica je, stoga, primarno njihovog mogućeg utjecaja na neizvjesnost poslovnog okruženja unutar kojeg se donose investicijske odluke. *Bernanke (1983)* pojašnjava kako tvrtke zbog neizvjesnosti o budućim kretanjima cijena nafte nastoje odgoditi planirane investicije. Usporedno s rastom nesigurnosti glede budućih cijena nafte, raste i vrijednost odgođenih, do tada planiranih investicija, dok motivacija za daljnjim investicijama opada. Ova neizvjesnost ima implikacije i na strani ponude i na strani potražnje. Neizvjesnost proizlazi iz očekivanja o budućim cijenama nafte, dakle troškovima inputa, odnosno iz očekivanja o budućim prihodima koja proizlaze iz očekivanja o potencijalnim promjenama u potražnji za finalnim proizvodom tvrtke. Od ranijih istraživanja koja su promatrala međuodnos

---

[65] U odnosu na klasične; kamatnu stopu, realni devizni tečaj, mjere monetarne i fiskalne politike.
[66] U ekonomskoj literaturi pojam nepovratnoga troška (*engl. sunk cost*) odnosi se na izgubljeno ulaganje, čiji ishod ne možemo promijeniti donošenjem odluka u sadašnjosti (*Arnold, 2008*).
[67] Onih kod kojih nema nepovratnih troškova.

nesigurnosti glede budućih cijena energije i investicija mogu se istaknuti i radovi *Uri (1980)* i *Glass i Cahn (1987).* Povezujući cijene energije i neizvjesnost na razini industrije, *Uri (1980)* tvrdi kako su cijene nafte važna determinanata investicija na razini industrije kao i na agregatnoj razini. *Glass i Cahn (1987)* zaključuju kako rast cijena energije smanjuje agregatnu razinu investicija, pri čemu autori zanemaruju aspekt neizvjesnosti glede budućih cijena energije.

Rast cijena nafte čini naftu manje poželjnim proizvodnim inputom u odnosu na ostale oblike energije, kao i manje zastupljenim u omjeru energija-rad-kapital, pri čemu stupanj supstitucije proizvodnih inputa ovisi kako o tehničkim mogućnostima, kao i o trošku (isplativosti) supstitucije. Upravo je procjena troška, odnosno isplativosti supstitucije nafte ostalim proizvodnim inputima najveći izazov (i jako nezahvalan posao) jer podrazumijeva poznavanje budućih kretanja cijena nafte, odnosno troška/cijene ostalih proizvodnih inputa. U svom pregledu 375 različitih istraživanja o mogućnosti supstitucije proizvodnih inputa, *Broadstock et al. (2007*) navode da se energija i kapital generalno ponašaju kao komplementi ili slabi supstituti. Ako su nafta i kapital blagi supstituti, smanjenje korištenja nafte bi zahtijevalo značajan rast udjela kapitala u proizvodnom procesu kako bi se održala ista razina proizvodnje. Ako su pak energija i kapital komplementi, tada bi rast cijena nafte trebao rezultirati smanjenjem korištenja i energije/nafte i kapitala, povećavajući na taj način utjecaj rasta cijena nafte na gospodarstvo.

Iako se nafta najčešće promatra kao proizvodni input u proizvodnji, *Henriques i Sadorsky (2011)* smatraju da oko 98% svih dobara koje konzumiraju krajnji potrošači dolazi u doticaj s naftom u pojedinom segmentu vrijednosnog lanca od točke proizvodnje do prodaje. *Ferderer (1996)* također razmatra neizvjesnost glede budućih cijena nafte tvrdeći da porast cijena nafte utječe na gospodarstvo, između ostalog, i kroz smanjenje investicija. Uzimajući u obzir sadašnju vrijednost očekivanih budućih prihoda, neizvjesnost ne definira samo vrijednost pojedine investicije, već i vrijednost tvrtke koja ju poduzima (*Miller, 1998*). Ovome je nužno dodati i da je neizvjesnost glede budućih cijena nafte pozitivno korelirana s volatilnošću cijena nafte, neovisno o tome radi li se o rastu ili padu cijena nafte (*Elder i Serletis; 2009, Elder i Serletis; 2010*).

Postojeća literatura ukazuje na to da cijene nafte, i to mahom na razini poduzeća, imaju snažan utjecaj na investicijske odluke u realnom gospodarstvu i to mahom na mikrorazini (*Henriques i Sadorsky, 2011; Yoon i Ratti, 2011; Ratti et al., 2011; Mohn i Misund, 2009; Wang et al., 2017*). Fokusirajući se na razvijena gospodarstva, *Henriques i Sadorsky (2011), Yoon i Ratti*

(2011) i Ratti et al. (2011) nude empirijske dokaze da nesigurnost glede globalnih cijena nafte statistički značajno negativno utječe na investicije poduzeća. Uzimanjem u obzir nacionalne specifičnosti industrijske strukture, energetske intenzivnosti, uvozne ovisnosti o nafti kao i načina formiranja cijena naftnih derivata na nacionalnoj razini, rezultati bi kod manje razvijenih ekonomija, kao i onih u razvoju mogli biti znatno drugačiji (*Crompton i Wu, 2005*). U svom istraživanju utjecaja neizvjesnosti glede budućih cijena nafte na investicije i gospodarski rast u SAD-u, *Elder i Serletis (2010)* zaključuju da rast volatilnosti cijena nafte umanjuje investicije, kao i realni rast na agregatnoj razini. Do vrlo sličnih rezultata isti su autori došli analizirajući navedeno i u Kanadi (*Elder i Serletis, 2009*). Koristeći ECM model, *Yoon i Ratti (2011)* zaključuju kako rast nesigurnosti glede budućih kretanja cijena nafte smanjuje investicijsku osjetljivost investicija tvrtke u odnosu na njen rast prodaje. Autori također ističu i kako je negativan utjecaj neizvjesnosti na investicije prisutan neovisno o energetskoj intenzivnosti pojedine industrije. Analizirajući podatke nefinancijskih tvrtki u 15 europskih zemalja (i 25 različitih industrija) u periodu od 1991 do 2006, *Ratti et al. (2011)* su utvrdili da u 14 od 15 analiziranih zemalja relativne cijene energije negativno utječu na investicije na razini tvrtke.

U novijem istraživanju reakcije velikog broja nefinancijskih poduzeća u Kini, u periodu od trećeg tromjesečja 2004. do posljednjeg 2014. g., *Wang et al. (2017)* pokazuju da neizvjesnost glede međunarodnih cijena nafte negativno utječe na investicije na razini poduzeće, pri čemu je negativni efekt izraženiji kod privatnih u odnosu na one u državnom vlasništvu.

S obzirom na neospornu važnost investicija u gospodarstvu, a uvažavajući činjenicu da su investicije komponenta BDP-a koja je u promatranom razdoblju pokazala naveće oscilacije (o navedenom detaljnije u poglavlju *3.5. Analiza kretanja investicija*), istraživanjem će biti obuhvaćena i analiza utjecaja cijena nafte na iste.

2.2.6. Problem asimetrije utjecaja cijena nafte na gospodarstvo

Objašnjenje asimetričnosti utjecaja cijena nafte ističe da dok porast cijena nafte ima jasan negativan utjecaj na rast BDP-a, pad cijena nafte nema statistički značajan utjecaj na ekonomsku aktivnost. *Mork (1989)* je među prvima istražio asimetričnost reakcije promjene BDP-a na promjene cijena nafte koristeći realne cijene nafte, te razlučujući periode rasta od perioda pada cijena nafte. Njegova analiza za gospodarstvo SAD-a pokazuje kako je korelacija između pada cijena nafte i gospodarskog rasta vrlo niska, gotovo jednaka nuli. *Mory (1993)* je na tragu istraživanja *Morka (1989)* razložio promjene cijena nafte na pozitivne i negativne te

konstatirao da pozitivne promjene, za razliku od negativnih, Granger uzrokuju ključne makroekonomske pokazatelje u SAD-u.

Postojanje asimetričnosti utjecaja potvrdilo je još nekoliko studija *(Mork, Olsen i Mysen, 1994*; Lee et al., 1995; Ferderer, 1996; Hamilton, 1996; Davis i Haltiwagner, 2001; Cuñado i Pérez de Gracia, 2003*; Jimenez-Rodriguez i Sanchez, 2005*[68]). Hamilton (1996)* je uvrštavajući pojavu asimetrije u pokazatelj promjena cijena nafte (NOPI), pokazao da i dalje postoji stabilna negativna korelacija između naftnih šokova i razine proizvodnje. *Davis i Haltiwagner (2001)* su, također, uvažili pojavu asimetrije prilikom konstrukcije vlastitog pokazatelja. U nešto kasnijoj studiji *Jimenez-Rodriguez i Sanchez (2005)* su permutacijom različitih specifikacija cijena nafte, uključujući i one koji imaju ugrađenu pretpostavku asimetrije, testirali utjecaj naftnih šokova na gospodarstva G-7, euro zone i Norveške, dokazujući kod većine analiziranih gospodarstava snažniju reakciju uslijed rasta cijena nafte. *Engemann et al. (2011)* na tragu navedenih zaključaka, istražujući utjecaj naftnih šokova na poslovne cikluse u SAD-u, također konstatiraju da rast cijena nafte povećava vjerojatnost ulaska gospodarstva u recesiju. S druge strane, rastući broj znanstvenika, predvođenih *Kilianom i Vigfussonom (2009; 2011a; 2011b),* nastoji osporiti hipotezu o postojanju asimetrije. *Herrera et al. (2011)* ispituju različite asimetrične specifikacije u odnosu između realnih cijena nafte i indeksa industrijske proizvodnje u SAD-u na sektorskoj razini. Autori pronalaze dokaze u prilog asimetriji na sektorskoj razini, posebice kod energetski intenzivnih sektora, ali ne i na agregatnoj razini.

Vrijedno je istaknuti i istraživanje *Herrera et al. (2015)* koji, koristeći mjesečne podatke (01/1974-07/2010) na uzorku od 18 OECD zemalja ispituju prirodu odnosa industrijske proizvodnje i realnih cijena nafte. Autori zaključuju da asimetrična priroda utjecaja koja se navodi u prijašnjoj literaturi nije primjenjiva na analiziranom uzorku, odnosno da makroekonomski pokazatelji evidentno ne reagiraju asimetrično na promjene cijena nafte. Oprečno navedenom, *Kocaaslan (2019)* nudi dokaze o postojanju asimetrije u reakciji nezaposlenosti na neizvjesne promjene (volatilnost) cijena nafte u SAD-u (1974:Q2-2017:Q4). Značajno je istaknuti i da *Herrera et al. (2015)* navode da je gotovo sve što znamo o asimetričnom utjecaju cijena nafte na gospodarstvo bazirano na istraživanjima za SAD,

[68] * - na uzorku OECD zemalja

temeljem kojih se donose zaključci i generalne teorijske postavke koje, kako se čini, ne vrijede na ostalim (OECD) gospodarstvima.

Pitanje koje se nameće je i pitanje izvora asimetrije. Drugim riječima, koje promjene u gospodarstvu, na različitim razinama, utječu na asimetričnu reakciju makroekonomskih pokazatelja na promjene cijena nafte. Iako je pretpostavka asimetrije sve šire prihvaćena u akademskim krugovima, broj istraživanja koja se bave njenim potencijalnim izvorima i dalje je relativno skromna. Klasična teorija makroekonomskog šoka na strani ponude može pojasniti pad realne gospodarske aktivnosti i proinflatornu prirodu naftnih šokova, ali ne objašnjava pojavu asimetrije. *Hamilton (2008)* tako ističe da je utjecaj cijena nafte na output ograničen kod ovog modela udjelom energije (i troškova iste) u proizvodnoj funkciji, a ista se ne mijenja ni dovoljno brzo ni dovoljno često da bi mogla pojasniti asimetriju. Doista, osjetljivost outputa u odnosu na cijene energije – nafte, trebala bi biti ograničena na udio troška energije – nafte u ukupnom trošku proizvedenog outputa. *Herrera et al. (2015)* ističu da navedeni udio kod OECD zemalja ne doseže niti 5%. Iz tog je razloga niz studija nastojalo izolirati i istražiti preostale moguće razloge asimetričnog utjecaja naftnih šokova na gospodarsku aktivnost: mogući utjecaj monetarne politike, troškova prilagodbe, te asimetriju utjecaja cijena nafte na cijene naftnih derivata. Zaključci istih predstavljeni su sljedećim odjeljcima.

2.2.6.1. Monetarna politika kao mogući izvor asimetrije

Monetarna politika nudi moguće objašnjenje asimetričnog odgovora gospodarstva na promjene cijena nafte, pri čemu je nekoliko studija nastojalo istražiti taj mehanizam, među prvima *Tatom 1988; 1993).* Koristeći pokazatelj koji uvažava mogućnost asimetrije, *BGW (1997)* su u svom istraživanju dokazali tezu o kanalu monetarne ekonomije kao eksplanatornom mehanizmu pojave asimetrije u odnosu cijena nafte prema gospodarskim kretanjima.

S druge strane, *Ferderer (1996)* tvrdi kako monetarna politika u njegovom modelu ne nudi objašnjenje pojave asimetrije. *Ferderer (1996)* je u svojoj studiji nastojao ne samo dokazati asimetriju, već i istražiti njene moguće uzroke, te se fokusirao na antiinflacijske mjere monetarne politike, tzv. sektorske šokove i faktor neizvjesnosti. Njegovo istraživanje pokazuje kako monetarna politika ne reagira asimetrično na porast/pad cijena nafte, pa se, sukladno tome, asimetričan utjecaj cijena nafte na gospodarstvo ne može u cijelosti objasniti mjerama monetarne politike. *Balke, Brown i Yücel (1999, 2002)* u svom radu, na primjeru SAD-a,

također tvrde da odgovor FED-a na promjene cijena nafte nije uzrok asimetrije. *Lilien (1982) i Hamilton (1988)* su istražili kako promjene cijena nafte stvaraju sektorske neravnoteže mijenjajući ravnotežne odnose među sektorima. Primjerice, porast (pad) cijena nafte rezultirao bi kontrakcijom (ekspanzijom) energetski intenzivnih sektora i ekspanzijom (kontrakcijom) energetski efikasnih sektora. Prilagodbe u proizvodnji zahtijevaju preinake koje ne mogu biti ostvarene u kratkom roku, a posljedica je rastuća nezaposlenost i suboptimalna iskorištenost resursa pri porastu cijena nafte.

U nešto kasnijem radu, *Hamilton i Herrera (2004)* su revidirali analizu *Bernanke et al. (1997)* te su, koristeći dulje vremenske odmake, konstatirali da naftni šokovi imaju puno jači neposredni efekt na smanjenje realnog outputa u SAD-u, implicirajući da monetarna politika ima slab utjecaj na stvarne posljedice naftnog šoka na gospodarstvo. Od novijih radova, koji također sa sumnjom promatraju monetarnu politiku kao izvor potencijalnog asimetričnog odgovora gospodarstva na naftne šokove (opet u SAD-u), mogu se istaknuti istraživanja *Herrera i Pesavento (2009), Kilian i Lewis (2011) Kilian i Vigfusson (2011a).*

2.2.6.2. Troškovi prilagodbe kao mogući izvor asimetrije

Prema *Hamiltonu (1988)*, troškovi prilagodbe bi mogli biti izvor asimetrične reakcije gospodarstva na cijene nafte; rast cijena nafte usporava gospodarski rast, dok ga pad cijena potiče. Ipak, trošak prilagodbe na promjene cijena nafte usporava realni rast neovisno o smjeru u kojem se cijene nafte mijenjaju. *Lilien (1982)* i *Hamilton (1988)* su istraživali način na koji promjene cijena nafte rezultiraju sektorskim neravnotežama. *Atkeson i Kehoe (1999)* su proučavali kako tzv. „putty-clay“ tehnologija[69] reagira na promjene cijena nafte. *Ferderer (1996)* ističe kako nesigurnost glede budućih kretanja cijena nafte može negativno utjecati na gospodarstvo reduciranjem potražnje za investicijama. Ovu je teoriju moguće u literaturi naći pod nazivom teorija nepovratnih investicija (*engl. irreversible investment theory, Pindyck, 1991; Rotemberg i Pindyck, 1984*). *Bernanke (1983)* ističe kako će tvrtke suočene s rastućom nesigurnošću glede budućih cijena sve izglednije odgađati nepovratne investicije. Asimetrija

[69] Tehnologija kod koje je omjer energije/kapitala/rada u odnosu na output u kratkom roku fiksan, kao posljedica komplementarnosti proizvodnih inputa, a u dugom roku varijabilan.

uzrokovana odgodom nepovratnih investicija poznata je pod nazivom načelo loših vijesti (*engl. „the bad news principle“;* prema *Bernake, 1983*).

S druge strane, *Edelstein i Kilian (2007)* tvrde da nije moguće odbaciti hipotezu simetrije u SAD-u. Tvrde da postoji slaba asimetrija u pojedinim segmentima (primarno rudarstvu/eksploataciji nafte), ali ne i na agregatnoj razini.

2.2.6.3. Cijene naftnih derivata kao mogući izvor asimetrije

Moguće je i da prilagodba cijena naftnih derivata doprinosi (je uzrok) asimetriji utjecaja cijena nafte na gospodarstvo.

Mnoga istraživanja su ekonometrijski potvrdila stalne tvrdnje javnosti o bržem rastu cijena naftnih derivata u slučaju rasta cijena nafte, negoli njihova pada u slučaju pada cijena nafte. *Bacon (1991)* donosi spomenute dokaze za Veliku Britaniju (1982-1989) te uvodi termin "*rockets and feathers*" u svom istraživanju cijena naftnih derivata 1991. godine. Od pojave navedene studije pa do danas javlja se rastući interes znanstvenika za istraživanjem pojave asimetrične cjenovne prilagodbe, kao i tržišnih fenomena koji ju na tržištima naftnih derivata uzrokuju. Unatoč važnosti i privlačnosti teme koja je, kako je istaknuto, privukla pažnju niza znanstvenika, rezultati studija nisu jednoznačni. Različiti autori koriste različitu metodologiju kao i frekvencije podataka kojima testiraju prisutnost asimetrične cjenovne prilagodbe na različitim tržištima, što je moguće i razlog zašto dolazi do nerijetko značajnih odstupanja u rezultatima.

U ekonomskom smislu, preduvjet za cjenovnu prilagodbu je postojanje vertikalno integriranog tržišta na kojem se cijene na nižim, maloprodajnim razinama prilagođavaju cijenama na višim razinama; proizvodnje ili veleprodaje. Na primjeru tržišta naftnih derivata to znači da se cijene naftnih derivata prilagođavaju veleprodajnim cijenama derivata, odnosno cijenama nafte (koje predstavljaju input i za veleprodajne cijene). U tom smislu cjenovna se asimetrija može pojaviti između cijena nafte i veleprodajnih cijena naftnih derivata, cijena nafte i maloprodajnih cijena naftnih derivata te veleprodajnih i maloprodajnih cijena naftnih derivata.

Tržišta naftnih derivata su manja lokalna tržišta u odnosu na tržište sirove nafte koje predstavlja globalno tržište u terminima prodanih i kupljenih količina. Kao rezultat, cijene nafte direktno određuju cijene naftnih derivata, dok obratno ne vrijedi. Kako cijene nafte direktno određuju

cijene naftnih derivata, u odsustvu eksternih poremećaja među njima postoji dugoročan ravnotežni odnos. Eksterni poremećaji u ovom sustavu (primjerice skok cijena nafte zbog geopolitičkih napetosti u nekoj od ključnih zemalja izvoznica) rezultirat će kratkoročnom i dugoročnom prilagodbom krajnjih cijena cijenama nafte. Naime, prodavatelji prilagođavaju cijene zbog maksimiziranja/optimiziranja profita, dok cijene u dugom roku odražavaju ograničenost nekog dobra u smislu dostupnih količina. U kratkom roku, smatra se da isključivo cijene nafte definiraju promjene cijena naftnih derivata. Cjenovna elastičnost u kratkom roku je iznimno niska jer naftni derivati nemaju adekvatne supstitute u kratkom roku; stoga potrošači na rast cijena reagiraju obuzdavanjem potrošnje (zbog izraženog efekta dohotka), a ne supstitucijom naftnih derivata[70].

Kada se uzme u obzir navedeno, može se uslijed promjene cijene nafte očekivati i prilagodba cijena naftnih derivata. Prilagodba cijena podrazumijeva promjenu cijene u smislu promjene visine cijene i vremena potrebnog za cjenovnu prilagodbu. Ako je promjena cijena naftnih derivata jednaka promjeni cijena nafte; smjerom, jačinom i vremenom prilagodbe, tada je cjenovna prilagodba simetrična. U protivnom, razlike u brzini i/ili jačini i vremenu potrebnom za prilagodbu krajnjih cijena rezultirat će cjenovnom asimetrijom.

U kontekstu mehanizma prilagodbe cijena postoje dva osnovna tipa asimetrije, a prikazana su Grafikonima 2.3.6.1. i 2.3.6.2. gdje se pretpostavlja da cijena krajnjeg proizvoda, outputa (p^{out}), ovisi o cijeni inputa (p^{in}). Na grafikonima su prikazane dvije specifične razlike u karakteristikama same asimetrije, a to su jačina i brzina. Grafikonom 2.3.6.1. prikazan je (isprekidanim linijama) slučaj kada cijena inputa (p^{in}) pada što je popraćeno nejednakim padom cijene krajnjeg proizvoda, outputa (p^{out}). Dakle, u ovom je slučaju cjenovna asimetrija posljedica razlike u jačini prilagodbe; prilagodba cijene krajnjeg proizvoda je nepotpuna ($\Delta p^{in} > \Delta p^{out}$). Jačina prilagodbe ovisi o smjeru kretanja cijene inputa, što je i temelj cjenovne asimetrije. Za razliku od predočenog slučaja, ako cijena inputa raste, prilagodba cijene outputa je trenutna i potpuna (puna linija).

[70] Kad je riječ o supstituciji naftnih derivata, treba istaknuti da dok je na polju supstitucije nafte kao energenta u proizvodnji energije postignut kakav-takav napredak razvojem alternativnih tehnologija, u sektoru transporta koji i dalje troši iznimne količine nafte, odnosno njenih derivata, nisu dosada zamijećene značajnije supstitucijske mogućnosti, posebno ne one koje bi bile cjenovno konkurentne naftnim derivatima, čak ni po višim cijenama (od trenutnih).

Grafikon 2.3.6.1.: Cjenovna asimetrija kao posljedica razlike u jačini prilagodbe

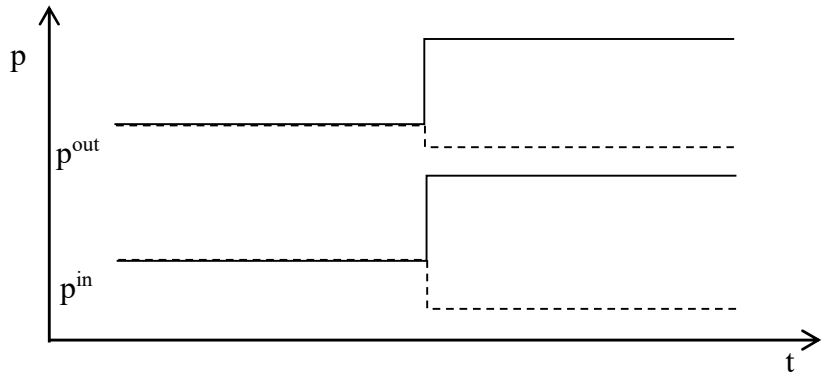

Izvor: Meyer i von Cramon-Taubadel (2004), str. 584.

Grafikonom 2.3.6.2. prikazana je (isprekidanim linijama) situacija kada se cijena krajnjeg proizvoda uslijed pada cijene inputa u potpunosti prilagođava smanjenju cijene inputa, ali s vremenskim odmakom *n* pa je cjenovna prilagodba potpuna tek u vremenu t_{1+n}. Slično situaciji kod prethodnog grafikona, ovdje brzina prilagodbe ovisi o smjeru kretanja cijene inputa; ako cijena inputa raste, prilagodba cijene outputa je i u ovom slučaju trenutna i potpuna (puna linija).

Grafikon 2.3.6.2.: Cjenovna asimetrija kao posljedica razlike u brzini prilagodbe

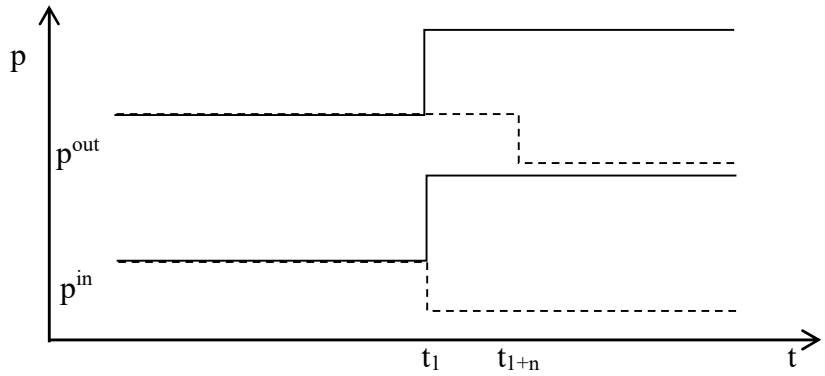

Izvor: Meyer i von Cramon-Taubadel (2004), str. 584.

Grafikonom 2.3.6.3. predstavljena je i, jednako moguća, kombinacija prethodnih dvaju slučajeva. Punim linijama prikazano je kako porast cijene inputa dovodi do porasta cijene outputa pri čemu je prilagodba postupna i potpuna u vremenu t_2 (potreban je dakle vremenski odmak $t_2 - t_1$). Nasuprot tome, uslijed pada cijene inputa prilagodba cijene outputa je postupna (cijena se prilagođava na niže kroz periode t_1, t_2 do t_3) i nepotpuna ($\Delta p^{in} > \Delta p^{out}$).

Istraživanja na podacima za SAD proveli su *Borenstein, Cameron i Gilbert (1997),* te *Brown i Yücel (1999). Borenstein, Cameron i Gilbert (1997)* su na uzorku polumjesečnih (dvotjednih)

cijena od ožujka 1986. do prosinca 1992., korištenjem ekonometrijske analize vremenskih nizova, dokazali postojanje cjenovne asimetrije. Drugim riječima, pokazali su kako se cijene naftnih derivata brže prilagođavaju porastu cijena nafte, negoli njihovom padu. U teorijskoj elaboraciji istraživanja kao moguće uzroke asimetrije autori ističu vremenski odmak potreban za usklađivanje zaliha odnosno proizvodnje, kao i tržišnu moć energetskih subjekata na tržištu. *Huntington (1998)* je preko asimetrije utjecaja cijena nafte na cijene naftnih derivata pokušao objasniti asimetričnost utjecaja cijena nafte na gospodarstvo. U svom istraživanju zaključuje kako gospodarstvo simetrično reagira na promjene cijena naftnih derivata, no same cijene naftnih derivata asimetrično reagiraju na promjene cijena nafte.

Grafikon 2.3.6.3.: Cjenovna asimetrija kao posljedica razlike u jačini i brzini prilagodbe

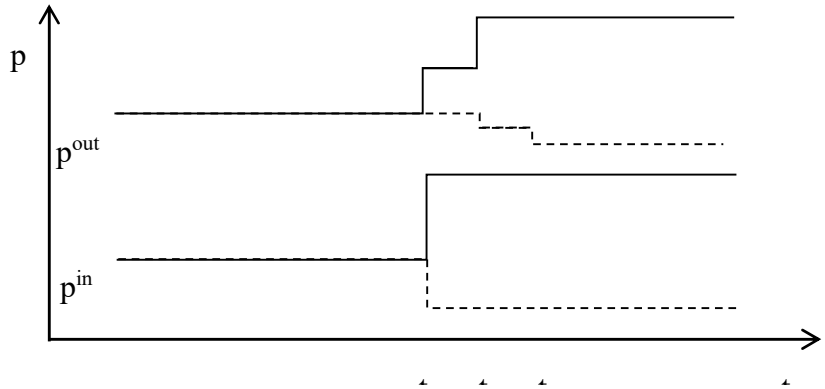

Izvor: Meyer i von Cramon-Taubadel (2004), str. 584.

Perdiguero-Garcia (2013) je proveo kvalitetnu analizu prisutnosti asimetrije na tržištima naftnih derivata nad nizom radova, kako bi na taj način pokušao identificirati njihove sličnosti i razlike (vidjeti također i *Ederington, 2018*). Tržišta nafte i naftnih derivata vertikalno su integrirana, dakle cjenovna prilagodba se odvija među istima. Pri tom istraživanje postojanja cjenovne asimetrije detektira je li prilagodba cijena potpuna i/ili pravodobna. U ovom se smislu može istraživati postojanje asimetrije ovisno o tome koji se segment (točnije koja dva) vertikalne integracije promatra: tržište nafte, veleprodajno i/ili maloprodajno tržište. Velika većina radova ispituje cjenovnu prilagodbu cijena naftnih derivata cijenama nafte (npr.: *Borenstein et al., 1997; Balke et al., 1998; Reilly i Witt, 1988; Godby et al., 2000; Galeotti et al., 2003; Radchenko, 2005a; Noel, 2007; Meyler, 2009, Liu et al., 2010; Atil et al. 2014,..*), ali postoje i manje učestala istraživanja o utjecaju veleprodajnih cijena na maloprodajne (npr: *Bacon, 1991; Karenbrock, 1991; Borenstein i Shepard, 1996; Eckert, 2002; Kufmann i Laskowski, 2005; Deltas, 2008; Bermingham i O'Brien, 2011,* itd). Upravo kod ispitivanja utjecaja cijena nafte na cijene naftnih derivata najčešće se dokazuje prisutnost cjenovne asimetrije. Ovo upućuje na zaključak da su maloprodajna tržišta naftnih derivata prilično

koncentrirana, odnosno slabo konkurentna, što je u skladu s teorijom o utjecaju tržišne moći na pojavu cjenovne asimetrije. Na nekonkurentnom tržištu jedna ili više tvrtki koje uživaju tržišnu moć prebacuju porast troškova puno brže na krajnje potrošače, negoli je to slučaj kod smanjenja cijene inputa. Na ovaj način maksimiziraju zarade, odnosno prilagođavaju cijene gotovo trenutno kako bi izbjegli smanjenje marži. U protivnom slučaju, tvrtke neće reagirati na smanjenje cijene inputa, dok god ne uoče smanjenje u obujmu prodaje (smanjenje potražnje). To će protumačiti kao smanjenje cijena od strane konkurenata pa će kao posljedicu i same prilagoditi cijene na niže (*Borenstein et al., 1997*).

Ako se promatra utjecaj cijena nafte na veleprodajne cijene, rjeđe se detektira cjenovna asimetrija. Valja istaknuti da je, uvažavajući činjenicu o izrazito visokom stupnju informiranosti o svjetskim cijenama nafte, tzv. „trošak traženja“ u ovom slučaju gotovo nepostojeći, odnosno vrlo nizak. Trošak traženja (*engl. search cost*) podrazumijeva trošak koji prati proces prikupljanja tržišnih informacija. Na savršeno konkurentnom tržištu postoji veliki broj kupaca i prodavatelja, a informiranost je potpuna. Kod nesavršenih tržišta, pak, postoji nekoliko tvrtki koje (čak i samo na lokalnoj razini) uživaju tržišnu moć zbog manjka konkurencije. U takvim okolnostima kupci mogu ili prihvatiti cijene određene na tako nesavršenom tržištu ili tražiti dobra na nekom drugom geografski udaljenijem tržištu. U stvarnosti, kupci nerijetko ni ne posjeduju relevantne informacije o cijenama na drugim tržištima upravo zbog troška traženja. Na nesavršenim tržištima tvrtke tako koriste dane uvjete bržim prilagođavanjem rastu cijena inputa i sporijim prilagođavanjem padu cijena inputa.

Prema *Lewisu (2011)*, ako su troškovi traženja na određenom tržištu visoki, i marže će biti više. Konkretnije, prema teoriji troška traženja, svaka benzinska postaja ima svojevrstan monopol na određenoj mikro lokaciji. Kada cijene nafte porastu, vlasnici benzinskih postaja brzo prilagođavaju cijene kako bi čim prije porast troška inputa prebacili na krajnje potrošače. U protivnom, ako cijene nafte padnu, isti će se sporije prilagoditi smanjenju cijene inputa kako bi barem privremeno mogli ostvariti veće marže. Tek kada se kupci aktiviraju u traženju najniže cijene, vlasnici benzinskih postaja uočit će pad u potražnji i kao odgovor na smanjenje potražnje reagirati prilagođavanjem cijena na niže (čime smanjuju i marže).

Tappata (2009) ističe kako se potražnja na benzinskim postajama većinom sastoji od potražnje svakodnevnih putnika koji tom rutom putuju na posao i dvaput dnevno prolaze kraj određene benzinske postaje (ili više njih). Kako benzinske postaje ističu trenutne cijene na način da su

iste vidljive iz automobila prilikom prolaska pored njih, *Tappata (2009)* smatra da se trošak traženja u biti svodi na mogućnost, odnosno voljnost određenog kupca da upamti i usporedi cijene derivata kojeg koristi[71]. Kako je u novijoj povijesti izrazita volatilnost jedna od osnovnih odlika cijena nafte, pa tako i naftnih derivata, može se istaknuti i navod *Radchenko (2005a)* koji ističe da porast volatilnosti cijena obeshrabruje kupce u traženju povoljnijih cijena, čime se smanjuje konkurencija među različitim benzinskim postajama.

Pored tržišne moći i troška traženja, u literaturi je moguće pronaći i dva (doduše rjeđe isticana) dodatna pojašnjenja za asimetrične reakcije cijena naftnih derivata na cijene nafte: troškove prilagodbe i prešutni sporazum. Troškovi prilagodbe predstavljaju troškove prilagođavanja cijena i/ili količina inputa odnosno krajnjih proizvoda (outputa). Primjer troškova prilagodbe su i tzv. „menu“ troškovi (*engl. menu costs*) koji uključuju trošak promjene nominalnih cijena, ispisa novih kataloga, distribucije informacija o promjeni cijene, kao i trošak inflacije. Prema *Kovenock i Widdows (1998),* ako se promjena cijena inputa percipira kao privremena, „menu“ troškovi će biti prvi impuls zbog kojeg će cijene krajnjih proizvoda ostati nepromijenjene uslijed smanjenja cijene inputa. S obzirom na priličnu koncentriranost energetskih tržišta, može se konstatirati da je na dotičnim tržištima prevladavajuća oligopolistička tržišna struktura (posebice na maloprodajnom tržištu) izvor tržišne moći. U tom smislu, tzv. prešutni sporazum *(engl. tacit collusion)* također vodi asimetričnoj prilagodbi cijena. Kako bi pospješile tržišni udio, tvrtke mogu biti u prešutnom dogovoru; ako porastu cijene inputa, tvrtke će brzo prilagoditi cijene outputa. Ako cijene inputa padnu, tvrtke će vrlo sporo prilagođavati svoje cijene kako bi izbjegle rizik percepcije konkurenata da smanjenjem marži žele povećati tržišni udio (i prekršiti prešutni sporazum). Prema *Borenstein et al.(1997)* tvrtke u prešutnom sporazumu mogu identificirati „prevarante“ određivanjem ciljane minimalne cijene. Primjerice, tvrtka koja postavi cijenu nižu od ciljane minimalne cijene, s ciljem stjecanja većeg tržišnog udjela, može biti kažnjena od strane preostalih tvrtki na tržištu.

Ako se promatraju geografske lokacije analiziranih tržišta, može se zaključiti da se istraživanja mahom rade na razvijenim „zapadnim“ tržištima, prije svega na američkom (npr.: *Karenbrock, 1991; Shin, 1994; Johnson, 2002; Chen et al., 2005; Radchenko, 2005a; 2005b, Ye et al., 2005; Al-Gudhea et al., 2007; Deltas, 2008; Lewis, 2011,..),* a potom na razvijenim europskim

[71] Naravno, ovo može biti slučaj samo u naseljenijim područjima gdje i postoji adekvatna konkurencija.

ekonomijama (npr.: *Bacon, 1991; Lanza, 1991; Asplund et al., 2000; Bettendorf et al., 2003; Galeotti et al., 2003, Grasso i Manera, 2007; Perdiguero-Garcia, 2010*, itd.). Navedeni radovi sačinjavaju veliku većinu ukupnog broja istraživanja. Najčešće se generiraju i obrađuju podaci na nacionalnoj razini, no nerijetko se istražuju i regionalna, odnosno lokalna tržišta naftnih derivata. Kod potonjih istraživanja posebno je izražen udio istraživanja na razvijenim zemljama jer uglavnom dostupnost kvalitetnih baza podataka pozitivno korelira sa stupnjem gospodarskog razvoja pojedine ekonomije. Također se može istaknuti da je vjerojatnost detekcije cjenovne asimetrije veća kada se analiziraju regionalna/lokalna tržišta, što je u skladu s hipotezom o postojanju veće tržišne moći na mikro lokaciji u odnosu na makro lokaciju.

Frekvencija podataka u istraživanjima varira od dnevnih do mjesečnih podataka, pri čemu se gotovo podjednako učestalo koriste tjedni i mjesečni podaci, a rjeđe dnevni. Važno je istaknuti istraživanja s dnevnim cijenama, iako su najmanje zastupljena s obzirom na prirodu promatranog tržišta, kao i ogromne prihode (pa i profite) koji se generiraju na dnevnoj bazi. Ako se cjenovna asimetrija i događa na dnevnoj bazi, ona se može „prikriti“ ako se koriste tjedni, a posebno mjesečni podaci. S druge strane, čak i jednodnevni odmak u prilagodbi cijena može energetskim subjektima osigurati „adekvatan“ porast prihoda, odnosno profita. Ovaj je tip istraživanja rijedak isključivo zbog loše dostupnosti podataka na dnevnoj bazi (rijetki primjeri istraživanja s dnevnim cijenama su: *Bachmeier i Griffin (2003), Gu i Jansen (2006), Noel (2006), Al-Gudhea et al. (2007), Oladunjoye (2008), Bettendorf et al. (2009), Noel (2009*)). Kada se korelira frekvencija korištenih podataka s rezultatima, može se uočiti da je prilikom korištenja dnevnih podataka puno veća vjerojatnost dokazivanja postojanja asimetrije, negoli je to slučaj kod korištenja tjednih, a posebno mjesečnih podataka. Ovo je i dodatan motiv za daljnja istraživanja asimetrične cjenovne prilagodbe na tržištima naftnih derivata korištenjem dnevnih podataka.

Ako se razmatra vremenski obuhvat korištenih vremenskih nizova može se naići na znatna odstupanja; u prosjeku se analizira vremenski period od oko deset godina, iako se u radovima nailazi na raspon podataka od nekoliko godina pa do preko petnaest. Prema *Perdiguero-Garcia (2013),* postoji negativna korelacija između prosječnog broja godina analiziranih u istraživanjima i detekcije cjenovne asimetrije. Dakle, istraživanja koja koriste duže vremenske nizove lakše odbacuju hipotezu o postojanju asimetrije. Cjenovna asimetrija kao tržišni fenomen očigledno nije ravnomjerno vremenski distribuirana, odnosno događa se u pojedinim trenutcima ili kraćim vremenskim periodima zbog čega ju je još teže „uhvatiti“. U tom smislu,

analiziranje iznimno dugih vremenskih perioda može biti kontraproduktivno jer se na taj način obuhvaćaju periodi različitih tržišnih uvjeta i različitih obrazaca ponašanja na tržištima, a što na koncu rezultira nemogućnošću donošenja ispravnih zaključaka.

Kada je riječ o metodologiji koja se koristi u istraživanjima, ona je prilično heterogena, pri čemu se ipak najučestalije koristi model korekcije greške. Neovisno o tipu korištenog modela (iako se model korekcije greške usporedno s razvojem metodologije pokazao primjeren za ovakva istraživanja) evidentno je da vrsta korištene metodologije nije opravdanje za oprečnost u rezultatima različitih istraživanja, odnosno ishod istraživanja ne ovisi o tipu korištene metodologije. Pored svega navedenog, može se još i dodati da se najčešće, gotovo uvijek (u preko 90% slučajeva), kao pokazatelj cijena naftnih derivata koriste cijene bezolovnog goriva naspram cijena dizela.

2.2.6.4. Ostali mogući izvor asimetrije

Transmisijski mehanizmi naftnih šokova na gospodarstvo proučavali su se i u sklopu modela realnih poslovnih ciklusa (*engl. real business cycle models*). Kod istih naftni šokovi su se (nakon 1970ih) smatrali ponavljajućim, predvidivim šokovima koje je ovakav tip modela uvažavao kao egzogene poremećaje na strani ponude. Tako su naftni šokovi za posljedicu imali privremeno odstupanje od dugoročne makroekonomske ravnoteže (*cf. Kim i Loungani, 1992; Mork et al., 1994; Brown et al, 2002*). *Lilien*-ova *(1982)* hipoteza disperzije (*engl. dispersion hypothesis*) pri tome je zauzimala centralno mjesto kod ovog tipa istraživanja. Hipoteza disperzije podrazumijeva da se značajan udio nezaposlenosti može pojasniti realokacijama sektorski specifične potražnje za radom (i kapitalom), posebno specijaliziranim. Navedena teorija modificira konvencionalnu specifikaciju makroekonomskog modela prema kojoj su jednako važne smjer i jačina promjene cijena nafte. Prema hipotezi disperzije, smjer promjene cijene (rast ili pad) nije uopće važan (*Loungani, 1986*). *Kim i Loungani (1992)* pak ne nalaze potvrdu navedene hipoteze te izražavaju sumnju u važnost alokativnih poremećaja na tržištu rada uslijed naftnih šokova.

Uzimajući asimetričnu reakciju gospodarstva SAD-a u 1980im godinama kao polazišnu točku istraživanja, *Bohi (1991)* pokušava identificirati mikroekonomske mehanizme putem kojih bi cjenovni naftni šokovi mogli rasprostirati svoj utjecaj diljem gospodarstva. *Bohi (1991)* se osvrće na strukturu potražnje kao i poremećaje na tržištu rada kao mogući mikroekonomski

kanal transmisije, no zadržava se na prilično teorijskim elaboracijama ne nudeći čvrstu modelsku osnovu temeljem koje bi se mogli izvući nedvojbeni zaključci. Strukturu potražnje su razmatrali i *Beresnahan i Ramsey (1992)* koji ističu da uslijed rasta cijena nafte proizvođači manjih (energetski efikasnijih) automobila proizvode punim kapacitetima, dok proizvođači većih (energetski neefikasnijih) automobila smanjuju stopu iskorištenosti proizvodnih kapaciteta.

Kao moguće pojašnjenje asimetrične reakcije BDP-a na naftne šokove *Bachmeier i Keen (2018)* navode i rigidnost nadnica. Rigidnost nominalnih nadnica prema dolje potencira pad outputa uslijed naftnog šoka. Rast cijena nafte povećava troškove inputa zbog čega se smanjuje potražnja za radnom snagom. Veći trošak energije smanjuje i potražnju kućanstava za istom, kao i ne energetsku potrošnju i investicije dok se, istovremeno, povećava ponuda rada. Navedeno stvara pritisak na pad nominalnih i realnih nadnica odnosno daljnji pad potražnje za radnom snagom i otpuštanja, čime se potencijalno može pojasniti asimetrična reakcija gospodarstava na naftne šokove.

Konačno se može zaključiti da, unatoč zaista respektabilnoj količini istraživanja u pojedinim segmentima utjecaja cijena nafte na pojedine makroekonomske pokazatelje (posebice u razvijenim ekonomijama), konsenzus glede mehanizama transmisije naftnih šokova na gospodarstvo, duljine trajanja i magnitude eventualnog utjecaja teško se nalazi. Upravo zbog toga je izuzetno važno kontinuirano provoditi istraživanja ne samo nad grupacijama zemalja već i nad pojedinačnim ekonomijama kako bi se sagledale njihove specifičnosti koje uvelike mogu moderirati način na koji se utjecaj cijena nafte rasprostire na njihova gospodarstva. S obzirom na recentnija istraživanja (ranije spomenuta unutar poglavlja *2.2.1. Utjecaj cijena nafte na gospodarski rast*) koja pridaju veliku važnost izvoru naftnog šoka, u nastavku je ponuđena analiza ključnih karakteristika svjetskog naftnog tržišta kao i svjetskih cijena nafte zajedno s, postojećim istraživanjima detektiranim, uzrocima njihovog kretanja.

2.3. KLJUČNE KARAKTERISTIKE SVJETSKOG NAFTNOG TRŽIŠTA

Moderna je civilizacija uvelike ovisna o fosilnim gorivima, a posebice o nafti koja je u prošlom stoljeću bila temelj za, do tada u povijesti neviđen, globalni gospodarski rast. Velike količine nafte raspoložive po povoljnim cijenama bila su pokretač gospodarskog rasta, ubrzanog tehnološkog napretka, rasta produktivnosti i životnog standarda u 20. stoljeću (*McNally, 2017*).

Štoviše, nafta je, s preko 4000 različitih derivata (*Odusami, 2010*), i dalje vodeći energent koji napaja globalni gospodarski rast s evidentnim utjecajem na mnoge aspekte našeg svakodnevnog života (*Xiong i Wu, 2009*).

Nafta kao energent još uvijek pokriva najveći dio svjetskog energetskog tržišta. Iako s vremenom sve više gubi udio na svjetskom energetskom tržištu, u korist prirodnog plina i obnovljivih izvora energije, potrošnja (ali i proizvodnja) nafte će i u budućnosti biti u porastu. Iako još uvijek o njoj ovise u znatnoj mjeri, potrošnja nafte u razvijenim zemljama stagnira. Tako je razina potrošnje nafte u zemljama OECD-a dosegnula, ili će vrlo brzo dosegnuti, svoj vrhunac *(Frans, 2017).* S druge strane, nafta je trenutno ključni preduvjet rasta zemalja u razvoju u Aziji, Latinskoj Americi i Africi (*McNally, 2017*) čija potrošnja kontinuirano raste. Upravo zbog navedene važnosti nafte, njene su cijene iznimno važna varijabla koja, u manjoj ili većoj mjeri determinira kretanje pojedinih makroekonomskih pokazatelja. Zbog toga je nužno razumjeti čimbenike koji utječu na njihovo kretanje.

Svjetsko tržište nafte podložno je različitim šokovima koji rezultiraju promjenama cijena nafte. Uzroci šokova na naftnim tržištima variraju od geopolitičkih previranja, napada na naftnu infrastrukturu, ponašanja ključnih proizvođača nafte, snažnih promjena globalne ekonomske aktivnosti, tehnološkog napretka u proizvodnim tehnologijama (kao i tehnologijama za pronalaženje novih nalazišta), do nesreća prilikom proizvodnje i transporta nafte, elementarnih nepogoda (npr. uragani) i vremenskih uvjeta i sl. (*Oladosu et al., 2018*).

Govoreći o cijenama nafte, najučestalije korišteni okvir za modeliranje cijena nafte je tzv. ″supply-demand framework″ odnosno pristup modeliranja odnosa ponude i potražnje za naftom (*Bacon, 1991; Al Faris, 1991; Dees et al., 2007; Krichene, 2007*). Specifičnosti tržišta nafte čine modeliranje cijena nafte velikim izazovom. Modeliranje ponude predstavlja poseban problem zbog nemogućnosti obuhvata svih relevantnih tržišnih uvjeta, kao i nemogućnosti predviđanja istih. Prilikom predviđanja buduće ponude i potražnje za naftom (kao neizostavnih komponenata modela cijene nafte) nailazi se na razne nesigurnosti koje se tiču geopolitičkih faktora, prekida u opskrbi, ekoloških katastrofa i tehnoloških otkrića. Kada bi potencijalni model i uspio izdvojiti spomenute utjecaje, ponovno preostaje problem nedovoljne upućenosti u faktore poput ponude nafte zemalja koje nisu članice OPEC-a, te samo ponašanje OPEC-a.

Cilj ovoga poglavlja je prvenstveno ukazati na dominantne trendove u proizvodnji i potrošnji nafte te ključne faktore ponude i potražnje za naftom kao fundamentalne odrednice kretanja njene cijene. Nadalje, dan je i osvrt na povijesno kretanje cijena nafte, s naglaskom na uzroke dosadašnjih naftnih šokova koji, prema ranije prezentiranim istraživanjima, uvelike mogu utjecati na reakciju pojedinog gospodarstava.

2.3.1. Ponuda nafte

Prema *Ceriću (2012, str. 24),* proizvodnja nafte, točnije njena industrijska eksploatacija, započela je krajem 19. stoljeća. Korijen komercijalizacije nafte bio je, između ostalog, pronalazak i komercijalna primjena motora s unutarnjim izgaranjem u kombinaciji s uvođenjem Fordove pokretne trake u tvornici automobila, a što je automobile učinilo pristupačnima širokim masama (i, ujedno, potenciralo visoke stope rasta potražnje za naftnim derivatima koji ih pokreću). Nafta polovinom 20. stoljeća postaje dominantan energent u SAD-u, a kroz naredna dva desetljeća trend se proširio i na ostatak svijeta, koji (poglavito razvijene zemlje) doživljava gospodarski rast završetkom 2. svjetskog rata. U to vrijeme, svekoliki gospodarski rast globalno „vuče“ potrošnju energije, a samim time i, sada najvažnijeg energenta, nafte.

Modeliranje ponude nafte predstavlja znatno veći izazov od modeliranja potražnje za istom zbog pitanja rezervi i, još značajnije, različitog ponašanja proizvođača nafte. U tom je smislu ustaljena praksa dijeljenja proizvođača nafte na članice OPEC-a i ostale, jer se smatra da tržište van OPEC-a djeluje konkurentno, dok je ponašanje samog OPEC-a vrlo kompleksno, te kao takvo predmet akademskih rasprava.

2.3.1.1. Ponuda nafte unutar OPEC-a

Počevši s naftnim šokovima sedamdesetih godina XX. stoljeća razvoj i utjecaj OPEC-a na tržištima nafte pomno je praćen kako od strane medija, tako i od strane akademskih krugova. Proučavanje ponude nafte od strane OPEC-a, koji se, barem inicijalno, nastojao nametnuti kao *price maker*, ključno je za razumijevanje tržišta nafte kao i kretanja cijena nafte. Proizvodnja zemalja članica OPEC-a (trenutno) čini više od 40% ukupne ponude sirove nafte (*Genc, 2018)*, dok zemlje članice OPEC-a posjeduju preko 80% trenutno dokazanih rezervi sirove nafte (pri čemu Venezuela i Saudijska Arabija zajedno u posjedu imaju trećinu ukupno dokazanih rezervi; *British Petroleum, 2016*). Također, proizvodni troškovi OPEC-a su, u prosjeku, puno niži u odnosu na proizvođače izvan OPEC-a osobito onih koji naftu proizvode iz nekonvencionalnih

izvora (*Adelman, 2002*). Navedeno predstavlja temelj tržišne moći OPEC-a. Ipak, ponudu OPEC-a vrlo je teško i kompleksno modelirati i sukladno tome, postoji čitavi niz istraživanja o samoj prirodi OPEC-a te njegovom utjecaju na formiranje cijena nafte (cf. *Kalymon, 1975; Fisher et al., 1975; Ezzati, 1976; Newbery, 1981; Griffin, 1985; Jones, 1990; Mabro, 1992; Gulen, 1996; Dees et al., 2007; Al-Qahtani A., Balistreri E. & Dahl C.; 2008; Alkhathlan et al., 2014, itd.).*

Generalno, može se izdvojiti nekoliko osnovnih karakteristika u ponašanju OPEC-a (*Fattouh 2007a*). Kao prvo, OPEC-ov utjecaj na cijene nafte nije konstantan, već varira kroz vrijeme, kao posljedica mijenjanja tržišnih uvjeta. No, to ne znači da sudionici na tržištu nafte mogu zanemariti utjecaj OPEC-a; OPEC je u nekoliko navrata rezanjem proizvodnje uspio spriječiti pad cijena nafte. Također, OPEC (ili točnije Saudijska Arabija) je koristeći svoje zalihe uspio nadoknaditi i prekide u opskrbi kao i moderirati poraste cijena nafte ograničavanjem njene ponude (kvotama). Pokušaji pronicanja u politiku ponude OPEC-a dodatno su otežani rastućom važnošću tržišta futuresa (*Fattouh, 2006*). Iako je OPEC u nekoliko navrata demonstrirao svoju snagu braneći cijene nafte na svjetskom tržištu, u nekoliko prigoda politike rezanja proizvodnje pokazale su se neučinkovite (za detalje *cf. Fattouh i Mahadeva, 2013*). Najveći problem u takvim situacijama je alokacija smanjenja proizvodnje (smanjenja kvota) među zemljama članicama, koje nerijetko ne poštuju dogovorene kvote (*Hamilton, 2008*). Prema *Radetzkom (2012),* djelovanje OPEC-a se promijenilo u suvremenim okvirima u odnosu na sedamdesete godine prošlog stoljeća. Ono što je sigurno je da, iako OPEC često predstavljaju kao najpoznatiji svjetski kartel, istraživanja pokazuju da članice OPEC-a ponekad surađuju usklađujući količinu ponude, a ponekad se natječu među sobom (*Huntington et al., 2013*).

Dok pojedina istraživanja upućuju na znatno povećanje cjenovne elastičnosti potražnje za naftom nakon krize 2008. godine (*Genc, 2017*), *Kaufman et al. (2004)* ističu, između ostalog, i rastuću važnost proizvodnje nafte izvan OPEC-a (što se posebno odnosi na Rusiju, a u novije vrijeme na SAD i Kanadu), a što predstavlja potencijalnu prijetnju OPEC-ovoj sposobnosti utjecaja na tržište, odnosno na kretanja cijene nafte. Može se konstatirati ipak da OPEC, u manjoj ili višoj mjeri, može posredno utjecati na cijene nafte kroz utjecaj na proizvodne kvote članica (*Wirl i Kujundzic, 2004; Kaufmann et al., 2008a*) i/ili određujući stupanj iskorištenosti vlastitih proizvodnih kapaciteta (*Kaufmann et al., 2004, 2008b*).

2.3.1.2. Ponuda nafte izvan OPEC-a

Ponuda nafte izvan OPEC-a ima značajan utjecaj na OPEC-ovu sposobnost utjecaja na formiranje cijena nafte. Proizvodnja nafte izvan OPEC-a nastoji se predvidjeti kvantificiranjem utjecaja geoloških i ekonomskih faktora, stoga prilikom modeliranja ponude nafte postoje dva osnovna pravca istraživanja, geofizički i ekonomski modeli (*Walls, 1992*).

Geofizički modeli baziraju se na tzv. Hubbertovoj teoriji vrhunca (*Hubbert, 1956*) koja tvrdi da za svako geografsko područje, od pojedinog naftnog polja pa do planeta u cjelini, količina proizvedene nafte teži tome da slijedi zvonoliku krivulju (normalnu distribuciju). Pri početku krivulje (prije vrhunca), zbog ulaganja u infrastrukturu, proizvodnja raste. Na kasnijem dijelu krivulje (nakon vrhunca), proizvodnja opada zbog iscrpljivanja izvora. "Peak Oil", poznat i pod nazivom Hubbertov vrhunac, odnosi se na zaseban povijesni događaj: globalni vrhunac (maksimum) proizvodnje nafte. Nakon ″Peak Oil″-a, prema Hubbertovoj teoriji vrhunca, globalna proizvodnja nafte ući će u fazu trajnog opadanja. Modeli ponude bazirani na Hubbertovoj teoriji bili su izrazito popularni 1970ih nakon čega su uslijedile kritike. Većina njih nalaže da, kako to tvrdi i *Watkins (2006),* definirane rezerve nafte koje je Hubbert smatrao statičnima, nisu statične, već variraju kroz vrijeme ovisno o ekonomskom i tehnološkom progresu. Sukladno tome, proizvodnja nafte (kroz vrijeme) nema oblik normalne distribucije.

Ekonomski modeli ponude nafte, s druge strane, ističu važnost faktora kao što su; realne cijene nafte, troškovi, regulatorni faktori (npr. koncesije), razvoj tehnologije, koji posredno (određivanjem veličine investicija) definiraju i ponudu nafte. Imajući spomenuto na umu, mnoge su studije nastojale procijeniti dugoročnu cjenovnu elastičnost ponude, te dokazale da je ona, iako pozitivna, uglavnom izrazito niska (*Krichene, 2006; Alhajji i Hunter, 2000; Gately, 2004*). Prilikom porasta cijena nafte, proizvođači ne podižu nužno razinu proizvodnje, i, s druge strane, ako se cijene nafte smanje to ne znači nužno da će se i količine proizvodnje smanjiti. Nadalje, kada je riječ o ponudi, period od pronalaženja novih nalazišta do njihove eksploatacije je relativno dug što, može se reći, i limitira značajnije reakcije ponude na cijenu.

Općenito, ekonomski modeli ponude sirove nafte koji su se bazirali na cjenovnoj elastičnosti nisu se pokazali pretjerano uspješnima kod procjena ponude nafte. Ovaj problem *Fattouh (2007a)* objašnjava postojanjem kompleksne interakcije između različitih faktora; geoloških

(rezerve, stupanj iskorištavanja rezervi, otkrića novih nalazišta), ekonomskih (cijene nafte i nova tehnološka postignuća), regulativnih (fiskalni sustavi) i političkih (sankcije, ratovi).

2.3.1.3. Proizvodnja nafte

Svjetska proizvodnja nafte u posljednjih je 50 godina (1965.-2015.) povećana gotovo tri puta (288,28%; podaci prema *British Petroleum, Statistical Review of World Energy 2016).* O količinama proizvodnje nafte od 1965. do 2015. od strane OPEC-a i preostalih zemalja svjedoče podaci prikazani Grafikonom 2.3.1.3.1. Počevši od 1979. vidljiv je znatan pad proizvodnje kao posljedica smanjenja proizvodnje od strane OPEC-a. OPEC-ove količine proizvodnje iz 1970ih postignute su tek koncem 1990ih, nakon čega je evidentan rastući trend proizvodnje nafte izvan kao i unutar OPEC-a.

Grafikon 2.3.1.3.1.: Proizvodnja nafte u tisućama barela dnevno

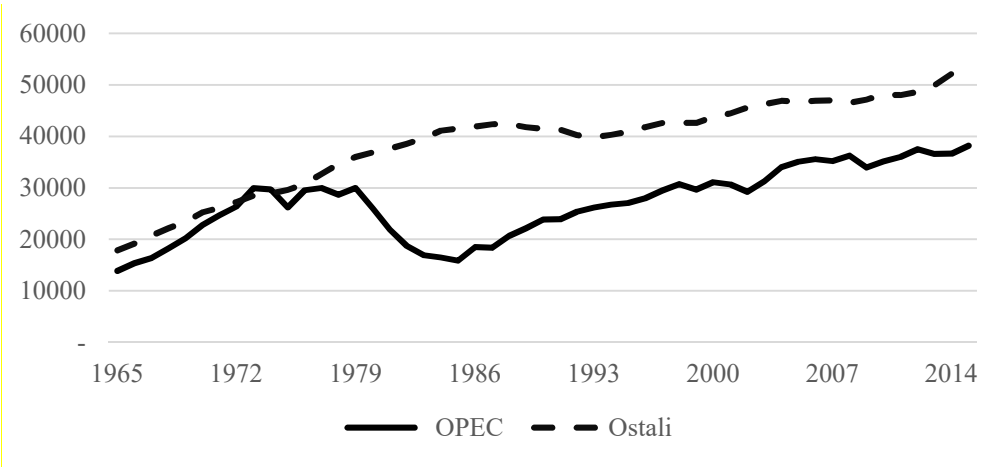

Izvor: prema BP Statistical Review of World Energy 2016 - data workbook: Oil production - barrels, preuzeto sa: http://www.bp.com/en/global/corporate/energy-economics/statistical-review-of-world-energy.html (07/2016)

Promatrajući strukturu proizvođača nafte (prema *BP, Statistical Review of World Energy 2016*), evidentna je znatna premoć proizvođača Bliskog Istoka s kojeg dolazi trećina proizvedene nafte[72]. Među njima valja istaknuti Saudijsku Arabiju koja (2015. godine) proizvodi 13% svjetske nafte. Posebno zanimljiva je i situacija SAD-a, koji je u posljednjih deset godina (2005.-2015.) udvostručio proizvodnju nafte čime je 2015., drugu godinu za redom, bio najveći proizvođač nafte na svijetu. Zahvaljujući rastu proizvodnje kao i energetske učinkovitosti, uvozna ovisnost o nafti u SAD-u pala je na niske brojke koje nisu viđene od 1980ih (*Finley,*

[72] Njihova proizvodnja od sredine 80ih godina 20. stoljeća, uz povremene oscilacije, bilježi trend rasta, te se u periodu od 1965. do 2015. godine povećala za 230%.

2012). Trend rasta proizvodnje vidljiv je i kod Kanade, koja je kroz isti period povećala svoju proizvodnju gotovo pet puta, a samo od 2010. do 2015. preko 60%.

Tablicom 2.3.1.3.1. predstavljeno je 10 najvećih proizvođača nafte u periodu od 2000. do 2015. godine. Ukupan tržišni udio[73] najvećih deset proizvođača nafte porastao je u posljednjih petnaest godina sa 59% na čak 67% što se može zahvaliti upravo trima najvećim proizvođačima; SAD-u, Saudijskoj Arabiji i Ruskoj Federaciji koji su u navedenom periodu povećali svoj (zajednički) tržišni udio za gotovo 7 postotnih poena. Drugim riječima, rast tržišnog udjela svih deset zemalja može se pripisati gotovo isključivo ovim trima proizvođačima.

Tablica 2.3.1.3.1.: Poredak prvih deset država najvećih proizvođača nafte (2000.-2015.)

Država	2000.	2005.	2010.	2015.
SAD	10,3%	8,4%	9,1%	13,0%
Saudijska Arabija	12,6%	13,3%	12,1%	13,0%
Ruska Federacija	8,8%	11,7%	12,4%	12,4%
Kanada	3,6%	3,7%	4,0%	4,9%
Kina	4,3%	4,4%	4,9%	4,9%
Irak	3,5%	2,2%	3,0%	4,5%
Iran	5,1%	5,1%	5,3%	4,2%
Ujedinjeni Arapski Emirati	3,6%	3,6%	3,5%	4,0%
Kuvajt	3,0%	3,3%	3,1%	3,4%
Venezuela	4,1%	4,0%	3,4%	3,1%
Udio prva 3 proizvođača	*31,7%*	*33,4%*	*33,6%*	*38,4%*
Udio prvih 10 proizvođača	*59,0%*	*59,9%*	*60,8%*	*67,5%*

Izvor: izrada autorice prema BP Statistical Review of World Energy 2016 - data workbook: Oil production - barrels, preuzeto sa: http://www.bp.com/en/global/corporate/energy-economics/statistical-review-of-world-energy.html (07/2016)

Kako je i uobičajeno, do sada je bilo govora isključivo o količinama proizvodnje na području određenih zemalja (ili grupacije zemalja), i prema netom iznijetom svega tri zemlje proizvode dvije trećine ukupne proizvodnje nafte. To upućuje na oligopolističku tržišnu strukturu (s rastom tržišnog udjela u promatranom periodu u korist SAD-a i Rusije). Ipak, naftne su kompanije uglavnom multinacionalne kompanije koje se natječu za koncesije i ekstrahiraju naftu (na različite načine) diljem svijeta zbog čega je rangiranje proizvodnje po kompaniji adekvatniji pokazatelj.

[73] Mjeren udjelom količine proizvodnje nafte u pojedinoj zemlji (bbl) u odnosu na ukupnu proizvodnju nafte globalno.

Sve do 70-ih godina 20. stoljeća naftnom su industrijom dominirale multinacionalne kompanije, tzv. *sedam sestara (engl. Seven Sisters)*; Anglo-Persian Oil Company (sada BP); Gulf Oil, Standard Oil of California (sada Chevron), Texaco (kasnije se udružio sa Chevronom); Royal Dutch Shell; Standard Oil of New Jersey (Esso/Exxon) i Standard Oil Company of New York (Socony; sada dio ExxonMobila). Početkom 1970ih, desetljeće ranije osnovan OPEC učvršćuje svoju tržišnu poziciju što je bilo popraćeno ranije pokrenutim trendom nacionalizacije naftnih tvrtki zemalja izvoznica nafte (*Sampson, 1975*). Razlog osnivanja OPEC-a bio je, između ostalog, i način raspodjele profita od prodaje nafte. Naftne su multinacionalne kompanije funkcionirale po principu prodaje naftnih derivata krajnjim potrošačima uz dodavanje izdašnih poreza/trošarina na naftne derivate. Time bi same kompanije ili države krajnje potrošnje ubirale veći dio zarade od nafte u odnosu na države s čijeg se teritorija ista crpila (čak i kad se uključe troškovi koncesije). Zbog navedenog, u 1970ima započinje trend nacionalizacije naftnih kompanija.

Prema PIW ljestvici[74] nacionalne naftne kompanije u 2015. godini i dalje drže dominantnu poziciju u svjetskoj naftnoj industriji[75] (prema količinama outputa). PIW ljestvica najvećih naftnih kompanija (prema količinama outputa) za 2015. navodi sljedećih 10 najvećih naftnih kompanija od kojih su podcrtane one u većinskom (ili isključivom) državnom vlasništvu:

1. Saudi Aramco (Saudijska Arabija)
2. National Iranian Oil Company (Iran)
3. China National Petroleum Company (Kina)
4. ExxonMobil (SAD)
5. Petroleos de Venezuela (Venezuela)
6. Royal Dutch Shell (Nizozemska/Ujedinjeno Kraljevstvo)
7. British Petroleum (Ujedinjeno Kraljevstvo)
8. Rosneft (Rusija)
9. Gazprom (Rusija)
10. Total (Francuska).

Prva tri mjesta zauzimaju nacionalne naftne kompanije (daleko najveći Saudi Aramco - Saudijska Arabija, National Iranian Oil Company – Iran i China National Petroleum Company

[74] Petroleum Intelligence Weekly je jedini sustav rangiranja koji uključuje i nacionalizirane i privatne naftne kompanije.
[75] Energy Intelligence web page, http://www.energyintel.com/pages/pr-piw-top-50-2015.aspx (pristup: 07/2016)

- Kina) , dok je preko 60% od 25 najvećih naftnih kompanija u većinskom državnom vlasništvu. Govoreći o trima zemljama s najvećom količinom proizvodnje nafte 2015., može se zamijetiti da je proizvodnja nafte nacionalizirana u Saudijskoj Arabiji i Rusiji, za razliku od SAD-a. U zemljama izvoznicama nafte, industrija nafte (i plina) sačinjava visok udio BDP-a, proračunskih prihoda i deviznih priljeva zbog čega za niz zemalja izvoznica sektor nafte (i plina) predstavlja ključnu determinantu ekonomskog, socijalnog i političkog stanja gospodarstva, što je posebno naglašeno u zemljama u razvoju.

2.3.2. Potražnja za naftom – izvedena potražnja

Promatrajući globalno, dvije su ključne determinante potražnje za energijom, pa tako i naftom; broj stanovnika i realni dohodak. Od 1900. godine svjetsko se stanovništvo gotovo učetverostručilo, realni je dohodak porastao 25, a potrošnja primarne energije 22,5 puta (*BP, Energy Outlook 2030, 2011*). Prema istom izvoru, u periodu od 2010. do 2030. godine očekuje se daljnji rast svjetske populacije za 1,4 milijarde kao i rast realnog dohotka od dodatnih 100%. Navedeno će potencirati daljnji rast i proizvodnje i potrošnje energije, a samim time i nafte. Nadalje je nužno istaknuti i različite reakcije razvijenih zemalja i zemalja u razvoju (primarno Kine, Indije, Brazila, Rusije) pri čemu je potražnja za energijom općenito osjetljivija na ekonomski rast, ali i manje osjetljiva na promjene cijene energije u zemljama u razvoju u odnosu na razvijene zemlje (*Huntington et al., 2017*).

Potražnja za naftom naziva se izvedenom potražnjom jer se, u stvarnosti, tek zanemariv udio nafte troši u nerafiniranom obliku. Ona se javlja kao ključni proizvodni čimbenik gotovo svih sektora modernih industrijaliziranih ekonomija; transporta, industrije, poljoprivrede, komercijalnih i javnih usluga i sl. (*Cooper, 2003*). Prema *Hirschu (2008),* nafta kao energent pokreće čitav niz transportnih sredstava; automobile, kamione, zrakoplove, brodove, vlakove, poljoprivrednu i vojnu opremu, a ujedno predstavlja i primarnu sirovinu za proizvodnju niza kemikalija bez kojih bi suvremeni oblik života bio nezamisliv.

Na globalnoj se razini daleko najveći dio nafte, preko 60%, koristi u transportu (u vidu različitih vrsta pogonskih goriva), oko 15% za neenergetske svrhe, 10% u industriji te nešto više od 10% u ostalim sektorima *(IEA, 2010b)*. Nafta još uvijek čini preko 94% ukupne energetske potrošnje transportnog sektora što svjedoči o još uvijek zanemarivom stupnju supstitucije fosilnih goriva inima u transportnom sektoru. Posljedica ovisnosti prometa o naftnim derivatima je i činjenica

da se od 1973. do 2013. udio prometa u sektorskoj strukturi potrošnje nafte povećao sa 45,4% na 63,8% (*IEA, Key World Energy Statistics, 2016*). Ključna primjena nafte proizlazi, dakle, iz činjenice da gotovo sva transportna sredstva današnjice pokreću derivati nafte, a funkcionalan transportni sektor nulti je uvjet modernog društva i gospodarstva (*McNally, 2017*). Pored navedenog, nafta je primarni input petrokemijskoj industriji, kao i ključna sirovina za široki dijapazon potrošačkih dobara poput plastike, sapuna, deterdženata, poliestera, odjeće, elektroničkih uređaja, gnojiva, pesticida, boja, lakova itd. Imajući navedeno u vidu, niti ne čudi da su, globalno gledano, isključivi izvori rasta potražnje za naftom u posljednja tri desetljeća transportni sektor (cestovni, zrakoplovni i pomorski promet) i petrokemijska industrija (*OPEC, 2010*). Shodno istaknutom, potražnja za navedenim proizvodima (derivatima nafte) rezultira potražnjom za ključnim inputom u proizvodnji istih – sirovom naftom.

Grafikon 2.3.2.1.: Svjetska potrošnja energije po oblicima 2015. (u milijunima tona ekvivalenta nafte[76] - mtoe[77])

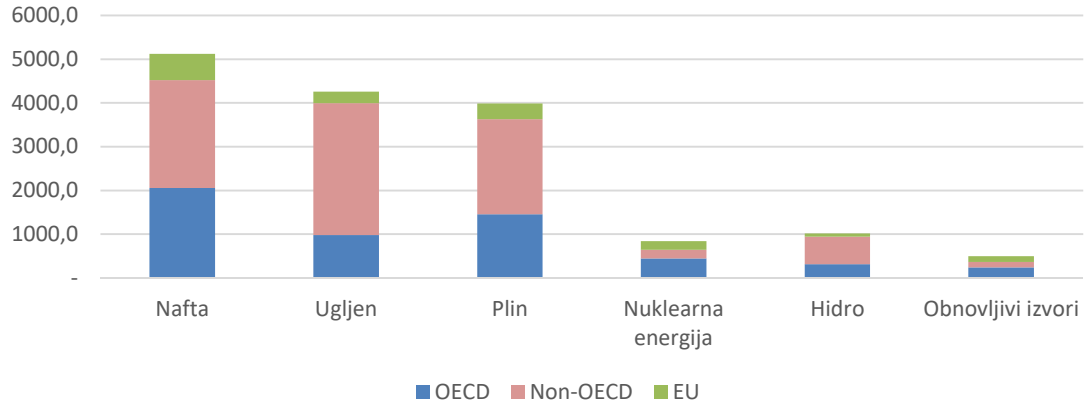

Izvor: obrada autorice prema: BP, Statistical Review of World Energy 2016 - data workbook: Oil production - barrels, preuzeto sa: http://www.bp.com/en/global/corporate/energy-economics/statistical-review-of-world-energy. html (07/2016)

Struktura potrošnje energije razlikuje se od države do države što je posljedica: razine realnog BDP po stanovniku, industrijske strukture, standarda i životnog stila stanovnika, geografske lokacije države i cijena energije (*Phoumin i Kimura, 2014*). Ipak, promatrajući globalno, nafta još uvijek ima najveći udio u strukturi potrošnje primarne energije, kako sugeriraju i podaci prikazani Grafikonom 2.3.2.1., a što je posebno izraženo u zemljama OECD-a. Više od trećine svjetske potrošnje energije otpada na naftu (*Rubin, 2012*). Štoviše, nafta će i dalje biti primarni

[76] IEA - International Energy Agency definira jednu tonu ekvivalenta nafte kao: 11.63 megavat sati (MWh), 41.868 giga džula (GJ), odnosno 1.42857143 tonu ekvivalenta ugljena (tce)
[77] Mtoe= 10^9 kgoe/kgen

izvor energije (čak i 2030. godine) s godišnjim stopama rasta potrošnje od 0,8% (*Schult-Bornemann, 2012*).

Grafikonom 2.3.2.2. prikazana je potrošnja nafte u tisućama barela nafte dnevno u periodu od 1965. do 2015. pri čemu su definirane tri kategorije potrošnje; potrošnja EU članica, zemalja OECD-a i onih koje to nisu.

Grafikon 2.3.2.2.: Potrošnja nafte u svijetu u tisućama barela nafte dnevno (1965.-2015.)[78]

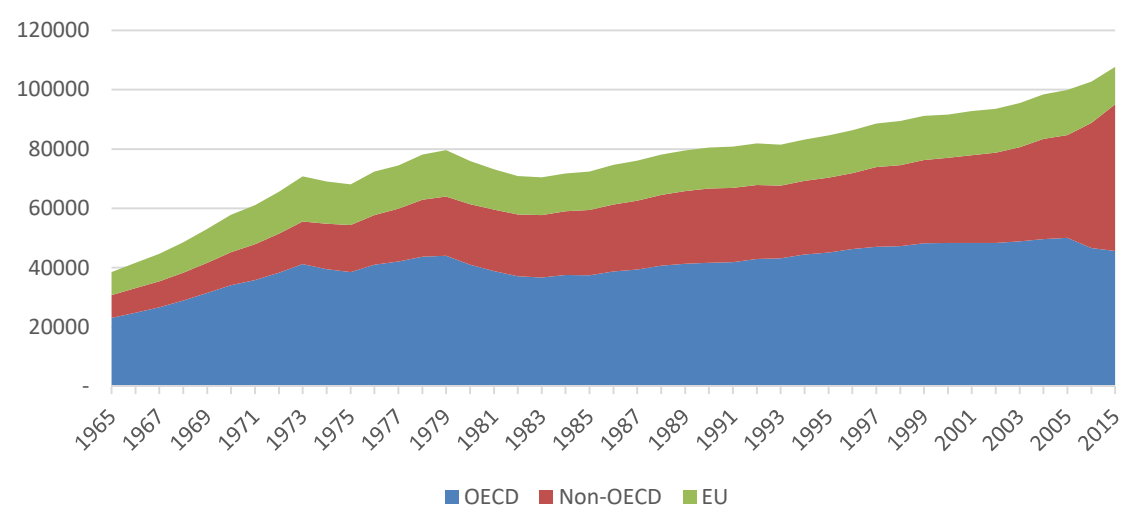

Izvor: obrada autorice prema BP Statistical Review of World Energy 2016 - data workbook: Oil production - barrels, preuzeto sa: http://www.bp.com/en/global/corporate/energy-economics/statistical-review-of-world-energy.html (07/2016)

Promatrajući cjelokupan period, evidentno je da je potrošnja nafte krajem razdoblja (2015. g.) gotovo 2,5 puta veća negoli je bila početkom razdoblja (1965. g.). Potrošnja nafte od strane zemalja OECD-a pala je početkom 1980ih što je direktna posljedica naftnih šokova u 1970im godinama prošlog stoljeća, odnosno energetskih prilagodbi gospodarstava OECD-a ka smanjenju ovisnosti o nafti gdje god je to moguće. Od početka 1980ih naovamo, potrošnja je nafte konstantno u porastu, čak i u godinama krize (2008., 2009.) s naglaskom na potrošnju zemalja izvan OECD-a gdje je drastično porasla u periodu od 2005. do 2015., za čak 41,42%. Najveći rast potrošnje u ovom su periodu zabilježile: Kina (73,46%), Indija (59,61%) i Brazil (48,67%) na koje otpada više od polovine ukupnog porasta potrošnje u ovoj kategoriji zemalja. Ipak, najveći je svjetski potrošač nafte SAD, koji troši oko petinu ukupne svjetske potrošnje, a

[78] OECD članice: Europa; Austrija, Belgija, Češka Republika, Danska, Estonija, Finska, Francuska, Njemačka, Grčka, Mađarska, Island, Irska, Italija, Luksemburg, Nizozemska, Norveška, Poljska, Portugal, Slovačka, Slovenija, Španjolska, Švedska, Švicarska, Turska, Ujedinjeno Kraljevstvo, ostale članice; Australija, Kanada, Čile, Izrael, Japan, Meksiko, Novi Zeland, Južna Koreja, Sjedinjene Američke Države.

slijedi, odnedavna, Kina čija potrošnja nafte iznosi 12,9%. *Hamilton (2011)* na istom tragu navodi kako su u periodu od 1998. naovamo, zemlje u razvoju u kojima se odvija proces industrijalizacije (primarno Indija i Kina) apsorbirale dvije trećine ukupnog rasta potrošnje nafte. Štoviše, isti autor navodi da će se vrlo sličan trend nastaviti i u budućnosti.

Nužno je naglasiti i značajan rast potražnje za naftom izvan OECD-a u periodu od 2005. do 2009., za razliku od potražnje unutar OECD-a koja se u istom periodu smanjila. Ovakva razlika u ponašanju zemalja dvaju različitih grupacija implicira i različitu elastičnost potražnje među njima. Evidentno i funkcija potražnje za energijom općenito, tako i naftom, ovisi o nivou razvijenosti gospodarstva (*Jobling i Jamasb, 2017*). Tako je uobičajeno da potrošnja energije, pa tako i nafte, raste puno brže u zemljama u razvoju u odnosu na razvijene zemlje, što je posljedica drugačije energetske strukture kao i niže energetske učinkovitosti (*Atkins i Tayyebi Jazayeri, 2004*).

Europska unija, je u istom periodu (od 1965. do 2015.) povećala svoju potrošnju nafte za 63,12%. Ipak, najveća razina potrošnje, od 15,63 milijuna barela dnevno, zabilježena je davne 1979. (period naftnog šoka) nakon čega je blago oscilirala na niže s konačnim trendom smanjenja potrošnje počevši od 2008. godine na današnjih (2015. g.) 12,7 milijuna barela dnevno (*BP, Statistical Review of World Energy, 2016*). S obzirom da ekonomska aktivnost pa ni realni BDP u promatranom periodu nisu zabilježili pad, ovaj podatak zorno oslikava reakciju Unije, odnosno njenih gospodarstava, na prve naftne šokove 1970ih godina, supstitucijom nafte ostalim (cjenovno prihvatljivijim i dostupnijim) energentima. Ovdje se potencijalno i krije pojašnjenje za eventualnu smanjenu osjetljivost gospodarstava na promjene cijena nafte.

Konačno, potražnja za naftom modelira se kao funkcija svjetske ekonomske aktivnosti i cijena nafte. Veza je pri tome jasna; viša ekonomska aktivnost povezana je s većom potražnjom za naftom, dok veće cijene nafte istu smanjuju. Velik broj istraživanja koncentrirao se stoga na procjene cjenovne i dohodovne elastičnosti potražnje za naftom, u dugom i kratkom roku. Za razliku od mnoštva studija fokusiranih na potražnju za energijom (općenito), akademski opus istraživanja potražnje za naftom je znatno skromniji. Većinom se ova istraživanja provode nad grupacijama zemalja iako niz autora navodi poprilične oscilacije kod procijenjenih rezultata (različitih zemalja).

Veza između potražnje i cijene nafte mjeri se elastičnošću potražnje tj. omjerom promjene u potražnji u odnosu na promjenu cijene. Tablicom 2.3.2.1. sumiran je pregled relevantnih studija kojima su analizirane cjenovne elastičnosti potražnje za naftom u kratkom i dugom roku[79].

Tablica 2.3.2.1.: Procjene cjenovne elastičnosti potražnje za naftom prema različitim studijama

Autor/ Godina	Kratki rok	Dugi rok	Uzorak
Dahl, 1993	od -0,05 do -0,09	od -0,13 do -0,26	Zemlje u razvitku
Peseran et al., 1998	-0,03	0,0 do -0,48	Azijske zemlje
Gately and Huntington, 2002	-0,05 -0,03	-0,64 -0,18 -0,12	OECD Zemlje van OECD-a Zemlje van OECD-a[80]
Krichene, 2002		-0,06 (1918-1999)	Svijet
Cooper, 2003	od 0,01 do -0,11	od 0,038 do -0,56	23 zemlje
Brook et al., 2004		-0,6 -0,2 -0,2	OECD Kina Ostatak svijeta
Griffin and Schulman, 2005		-0,36	OECD
Krichene, 2006	od -0,02 do -0,03	od -0,03 do -0,08	Razne zemlje
Altinay, 2007	-0,10	-0,18	Turska
Ghosh, 2007		-0,63	Indija
Narayan i Smith, 2007		od -0,002 do -0,071	Bliski Istok
Cologni i Manera, 2008		od -0,17 do -0,48	G7
Xiong i Wu, 2009		-0,365	Kina
Ziramba, 2010		-0,147	Južna Afrika
Tsirimokos, 2011	od -0,036 do -0,10	od 0,35 do 0,66	8 europskih ekonomija, SAD i Japan

Izvor: Obrada autorice prema *Fattouh (2007a)* i *Oladosu et al. (2018)*

Iz prikazanog je evidentan prilično širok raspon vrijednosti procijenjenih koeficijenata koji variraju od minimalno 0 do maksimalno -0,64. Unatoč tome, ipak se mogu izvući pojedini zaključci. Kao prvo, promjene cijene nafte imaju relativno mali utjecaj na potražnju za naftom, posebno u kratkom roku, i kao drugo, vrijednosti koeficijenata više su u dugom roku kao

[79] U literaturi se mnogo češće može naići na procjene koeficijenata cjenovne elastičnosti potražnje za naftnim derivatima (posebno benzinom) koje su, u prosjeku znatno veće (veći apsolutni iznosi koeficijenata). Kako se u nazivniku (po formuli za elastičnost) nalazi postotna promjena cijene naftnog derivata, uz pretpostavku nepromijenjenih poreza i rafinerijskih marži, 10%-tni rast cijene nafte će rezultirati skromnijim rastom cijene promatranog derivata. Uz nižu vrijednost nazivnika, rezultiraj ući koeficijent elastičnosti je (u apsolutnom iznosu) viši kad se mjeri na razini cijene derivata, nego li je slučaj kad se isti mjeri na razini cijena nafte.

[80] brzorastuće zemlje izvan OECD-a

direktna posljedica efekta supstitucije te efikasnijeg korištenja energije (*Fattouh, 2007a*). Navedeno je u skladu s općim mikroekonomskim zakonitostima koje impliciraju veće koeficijente cjenovne elastičnosti potražnje u dugom roku, kao posljedica veće količine vremena za prilagodbu ponašanja potrošača. Ipak, i u dugom roku vrijednosti prikazanih koeficijenata elastičnosti relativno su male implicirajući, između ostalog, i skromne mogućnosti supstitucije.

Vrijedno je istaknuti i istraživanje *Oladosu et al. (2018)* koji su meta analizom relevantnih istraživanja o cjenovnoj elastičnosti potražnje za naftom, između ostalog, kategorizirali rezultate obuhvaćenih studija po regijama (60% analiziranih koeficijenata odnosi se na europska gospodarstva). Dok se aritmetička sredina procijenjenih koeficijenata svih analiziranih studija kreće u rasponu -0,017/-0,023/-0,008 (kratki/srednji/dugi rok; redoslijedno), a medijan u rasponu -0,006/-0,011/-0,003, iste vrijednosti za europske ekonomije (van euro zone) upućuju na skromnije vrijednosti aritmetičke sredine (manja osjetljivost na promjene cijena). Navedeno je posebno izraženo u dugom roku.

U dugom je roku prosječni koeficijent cjenovne elastičnosti -0,008 u euro zoni, a 0,001 izvan nje, dakle pozitivna reakcija na promjene cijena u dugom roku! Što je važnije, i medijan upućuje na isti zaključak čime ponašanje ovih ekonomija odudara od svih ostalih istraživanjem obuhvaćenih ekonomija (izuzev Kine). Također, autori ističu smanjenje koeficijenata cjenovne elastičnosti u odnosu na prethodna desetljeća implicirajući manju osjetljivost potražnje na promjene cijena nafte. S druge strane, primjerice, *Genc (2017)* tvrdi kako je reakcije potražnje za naftom gotovo dvostruko snažnija u periodu nakon krize 2008. negoli u razdoblju prije iste. Ovakvu promjenu autor pojašnjava rekordnim (do tada u apsolutnom iznosu neviđenim) cijenama nafte koje su dramatično utjecale i na ponašanje potrošača u kriznom periodu.

Prilično širok raspon procijenjenih koeficijenata, posebice u dugom roku, posljedica je fundamentalnih i metodoloških faktora (*Oladosu et al., 2018*). Fundamentalni faktori podrazumijevaju razlike u uzroku naftnih šokova (poremećaji ponude/potražnje, geopolitički razlozi i sl.), karakteristike naftnog šoka (brzina, jačina, duljina trajanja i sl.), energetsku (naftnu) intenzivnost gospodarstva, fazu gospodarskog ciklusa kao i političke okolnosti u kojim se gospodarstvo nalazi te strukturne promjene gospodarstava.

Od metodoloških faktora može se istaknuti čitav dijapazon korištene metodologije (iako je daleko najzastupljenija VAR metodologija) koja producira, nerijetko, poprilične razlike u procijenjenim koeficijentima. Zbog svega navedenog, nikako se ne preporuča donositi konačne zaključke temeljem samo jedne studije, neovisno o njenoj kvaliteti, već je poželjno kombinirati rezultate veće količine studija (na istom uzorku) s po mogućnosti različitim metodološkim pristupima.

Važno je istaknuti da na potražnju, a tako i na ponudu nafte, osim trenutne cijene utječe niz faktora, od kojih su najvažniji cijene nafte u prethodnom razdoblju (najčešće godini) i dohodak (BDP). Cijene nafte u prethodnom razdoblju utjecat će na ponašanje potrošača, no da bi se dogodili značajni pomaci u potrošnji, ili točnije potražnji, nužne su značajne promjene u ponašanju potrošača. Potrebno bi bilo, primjerice, većinu vozila koja se u tom trenutku koriste zamijeniti energetski efikasnijim modelima. Naravno da se ovaj tip prilagodbe neće realizirati u kratkom roku (posebice ako je rast cijena nafte popraćen padom BDP-a). Zbog važnosti utjecaja dohotka na potražnju za naftom, isti je analiziran u nastavku kroz istraživanja o dohodovnoj elastičnosti potražnje za naftom.

Dohodovna elastičnost mjeri se kao omjer promjene dohotka, odnosno BDP-a, i količine potražnje. Tablica 2.3.2.2. daje sažeti prikaz rezultata studija koje su pokušale definirati vrijednosti koeficijenata dohodovne elastičnosti potražnje za naftom.

Tablica 2.3.2.2.: Procjene dohodovne elastičnosti potražnje za naftom prema različitim studijama

Autor/ Godina	**Dohodovna elastičnost - dugi rok**	**Uzorak**
Ibrahim i Hurst, 1990	>1,0	Zemlje u razvitku
Dahl, 1993	0,79 - 1,40	Zemlje u razvitku
Peseran et al., 1998	1,0 -1,2	Azijske zemlje
Gately i Huntington, 2002	0,56 0,53 0,95	OECD Zemlje van OECD-a Zemlje van OECD-a[81]
Krichene, 2002	0,53 (1918-1999) 0,42 (1918-1973) 1,45 (1973-1999)	Svijet
Brook et al., 2004	0,4 0,7	OECD Kina

[81] brzorastuće zemlje izvan OECD-a.

	0,6	Ostatak svijeta
Krichene, 2006	0,54 - 0,90	Razne zemlje
Altinay, 2007	0,61	Turska
Dees et al., 2007	0,17-0,98	Svijet
Ghosh, 2007	1,97	Indija
Narayan i Smith, 2007	0,204-1,816	Bliski Istok
Xiong i Wu, 2009	0,647	Kina
Ziramba, 2010	0,429	Južna Afrika
Tsirimokos, 2011	0,73-3,24	8 europskih ekonomija, SAD i Japan

Izvor: Obrada autorice prema *Fattouh (2007a)*

Vrijednosti prikazanih koeficijenata imaju vrlo široki raspon vrijednosti, od 0,2 do gotovo 2 (1,8). Kao što je to bio slučaj kod elastičnosti potražnje, i ovdje vrijednosti koeficijenata ovise o uzorku, promatranom periodu te primijenjenoj metodi istraživanja. Unatoč tome, može se zaključiti da su reakcije potražnje za naftom snažnije (apsolutna vrijednost procijenjenih koeficijenata je veća) kod promjena dohotka nego li kod promjena cijene nafte.

Na teritoriju RH zasada ne postoje relevantne procjene koeficijenata cjenovne i dohodovne elastičnosti potražnje, ali se može istaknuti jedno relevantno i relativno novo istraživanje. Procjenjujući cjenovnu i dohodovnu elastičnost potražnje za naftnim derivatima (bezolovnim motornim benzinom i dizelom) u RH (2006:M01-2010:M12), *Šušnjar (2014)* zaključuje da je potražnja za naftnim derivatima u Hrvatskoj prvenstveno određena kretanjem dohotka (kao i potražnja za automobilima kao temeljnim komplementarnim dobrima), dok je utjecaj cijene naftnih derivata na njihovu potrošnju mali, prema njegovom mišljenju, gotovo zanemariv. Autor navodi da je, na tragu zaključaka i ranije istaknutih istraživanja, i u Hrvatskoj dohodovna elastičnost (u apsolutnom iznosu) veća od cjenovne elastičnosti potražnje za naftnim derivatima. Važno je naznačiti i da je u periodu krize (2008:M08-2010:M12) došlo do statistički značajnog rasta koeficijenta dohodovne (dohodak je izražen realnim neto plaćama) elastičnosti potražnje za benzinom (sa 0,17 na 0,74 u kratkom roku, odnosno sa 0,73 na 1,1 u dugom roku), dok procijenjeni koeficijenti cjenovne elastičnosti potražnje za benzinom (kao i za dizelom[82]) u periodu krize nisu statistički značajni (cijena nije determinanta potražnje). Visine procijenjenih koeficijenata dohodovne elastičnosti potražnje, sukladno mikroekonomskoj

[82] Dobiveni rezultati dohodovne i cjenovne elastičnosti za dizelom u periodu 2006.-2010. nisu statistički značajni implicirajući da ni cijena ni dohodak ne utječu na potražnju za dizelskim gorivom.

teoriji, impliciraju da je riječ o nužnom (neophodnom) proizvodu. Nužno je istaknuti i veliki utjecaj turizma na potrošnju naftnih derivata pa tako rezultati istog autora ukazuju na pozitivnu cjenovnu elastičnost potražnje za naftnim derivatima od lipnja do listopada (unutar analiziranog perioda), implicirajući potpunu neosjetljivost na promjene cijena naftnih derivata unutar sezone.

U novije se vrijeme javljaju ideje i o asimetriji koju se također nastoji uvesti u model. *Gately i Huntington (2002)* tvrde da cjenovna elastičnost u kratkom roku ovisi i o tome jesu li cijene nafte rasle ili padale. Primjerice, rast cijena smanjiti će potražnju, no to ne znači da će smanjenje cijena koje bi moglo nakon toga uslijediti ponovno povećati potražnju na prijašnju razinu. Ako se kao posljedica rasta cijena investicije usmjere u energetski efikasne tehnologije, onda ponovno smanjenje cijena nafte možda i neće vratiti potražnju za naftom na prijašnju razinu. *Griffin i Schulman (2005)* tvrde da se ovdje ipak ne radi o asimetriji, te smatraju da ono što *Gately i Huntington (2002)* definiraju kao posljedicu cjenovne asimetrije, nije ništa drugo no posljedica energetskih tehnoloških ušteda.

Uspoređujući cjenovnu i dohodovnu elastičnost potražnje za naftom (1971-1997), *Gately i Huntington (2002)* također tvrde da u zemljama OECD-a (ali i u mnogim zemljama izvan njega) potražnja za naftom snažnije (negativno) reagira na rast cijena negoli na njihov pad (pozitivno). Ujedno, potražnja za naftom također snažnije (pozitivno) reagira na rast dohotka nego li na njegov pad (negativno). Autori navode i da je, u gotovo svim analiziranim ekonomijama (njih gotovo sto), brzina prilagodbe promjenama cijena sporija od brzine prilagodbe promjenama dohotka, što je najvjerojatnije posljedica vremena potrebnog za prilagodbu tehnologije, kupnju energetski efikasnijeg vozila i sl. Istovremeno, dohodovna elastičnost je viša izvan OECD-a, dok suprotno vrijedi kad je riječ o cjenovnoj elastičnosti. Konačno, ne manje važno, isti autori ističu da postoje znatne razlike u procjenama među analiziranim ekonomijama, što je posljedica različitih visina i varijabilnosti stopa rasta dohotka po stanovniku, kao i veze između rasta dohotka po stanovniku i potražnje za naftom (i energijom općenito), a što potencira važnost proučavanja pojedinačnih slučajeva (ekonomija).

Na istom tragu *Jobling i Jamasb (2017),* kao i *Gately i Huntington (2002*), zaključuju da postoji znatna razlika u koeficijentima dohodovne i cjenovne elastičnosti potražnje između razvijenih zemalja i zemalja u razvoju (1980-2012). Dohodovna je elastičnost znatno veća kod zemalja u razvoju (kod kojih je efekt dohotka šest puta veći u odnosu na razvijene), što implicira ulogu

potrošnje nafte u gospodarskom rastu i jednako tako lako može pojasniti relativnu otpornost zemalja u razvoju na naftni šok 2008. S druge je strane, efekt supstitucije dvostruko izraženiji kod razvijenih zemalja[83], što je donekle posljedica i politike subvencioniranja cijene fosilnih goriva u zemljama u razvoju. Još važnije, autori navode kako je (općenito, iako izraženije u zemljama u razvoju) dohodovna elastičnost izraženija uslijed pada dohotka, negoli uslijed njegova rasta. S druge strane, rast cijena nafte također prati veća osjetljivost potražnje u odnosu na njihov pad, ali ovaj je efekt ograničen na razvijene zemlje. *Rubin (2012)* ujedno ističe znatne razlike u cjenovnoj elastičnosti potražnje između razvijenih i zemalja u razvoju, navodeći gotovo potpunu neosjetljivost zemalja u razvoju na promjene cijena nafte. Ovakav rezultat pojašnjava mahom snažnim rastom dohotka Indije i Kine.

Također, dok pojedina istraživanja upućuju na znatno povećanje cjenovne elastičnosti potražnje za naftom nakon krize 2008. godine (npr. *Genc, 2017*), *Peersman (2009),* primjerice, tvrdi da se priroda naftnih šokova kroz vrijeme mijenja te da je cjenovna elastičnost potražnje za naftom s protokom vremena sve niža.

Evidentno, unatoč znatnom napretku u procjenama dohodovne i cjenovne elastičnosti potražnje za naftom, prostora za daljnji napredak još uvijek ima. Štoviše, bez obzira na kvalitetu relevantnih istraživanja, nužno je razmatrati i uvažiti specifičnosti pojedinog gospodarstva prilikom njegove analize, a shodno tome i primjene adekvatnog okvira nacionalne energetske (i ine) politike.

Na koncu, kako bi se umanjila uvozna ovisnost o energiji, pa i nafti (koja je iznimno visoka kako u EU28 tako i u RH), a jednako tako i podložnost naftnim šokovima, nužne su strukturne promjene u smjeru rasta energetske učinkovitosti (odnosno smanjenja energetske intenzivnosti) gospodarstava.

Korhonen i Ledyaeva (2010) ističu kako energetsku učinkovitost determinira proizvodna struktura gospodarstva. Primjerice, veći udio uslužnog sektora u BDP-u podrazumijeva i nižu potrošnju energije, s druge strane, veći udio industrije u BDP-u podrazumijeva i veću potrošnju energije po jedinici BDP-a (nižu energetsku učinkovitost). Nadalje, isti autori navode i važnost geografske veličine gospodarstva kao i populacije. Veća gustoća naseljenosti zahtijeva nižu

[83] U razvijenim je zemljama nafta primarno transportno gorivo.

potrošnju energije u transportnom sektoru (*ceteris paribus*). Važni su također i porezi kojima se na efikasan način mogu dugoročno stimulirati promjene u energetskoj strukturi gospodarstva. Trendovi rasta energetske učinkovitosti bilježe se od naftnih šokova 1970-ih i izraženiji su kod razvijenih gospodarstava.

Razvijena gospodarstva uglavnom imaju relativno niske pokazatelje energetske intenzivnosti i, shodno tome, relativno malo prostora za daljnja poboljšanja. Kako je u njihovoj energetskoj strukturi visok udio korištenja nafte u transportnom sektoru[84], upravo se u tom segmentu nastoje potencirati daljnja poboljšanja. S druge strane, kako navode *Jobling i Jamasb (2017*), energetska je intenzivnost nafte viša u zemljama u razvoju (čime, između ostalog opravdavaju i različite koeficijente cjenovne elastičnosti potražnje za naftom), gdje rapidno raste broj automobila po glavi stanovnika usporedno s rastom standarda. Ovakav će se trend teško značajno usporiti sve dok navedene ekonomije ne dosegnu viši stupanj razvijenosti (i životnog standarda). Ne smije se zanemariti ni utjecaj subvencija energenata (naftnih derivata) koje u tom slučaju (primjerice u Indiji) značajno narušavaju mogućnosti smanjenja energetske intenzivnosti. Uvođenje i primjena subvencija direktno utječe na tržišnu cijenu koja bi u njihovom odsustvu bila znatno viša te bi kao takova stimulirala nižu potrošnju energije i energetsku intenzivnost.

Konačno, iznimno je poželjna i diverzifikacija dobavnih pravaca nafte kao i stvaranje (nacionalnih) strateških rezervi kojima bi se trebalo omogućiti neometano funkcioniranje ekonomskih aktivnosti (u kratkom roku) uslijed poremećaja u opskrbi. U prvom, prema *Ju et al. (2016),* prednjače SAD, EU i Singapur, dok se u potonjem mogu istaknuti primjeri SAD-a i Japana kao primjeri dobre prakse[85].

---

[84] Zemlje OECD-a koriste oko 80% nafte u transportnom sektoru, dok je isti udio oko 15 postotnih poena niži kod zemalja u razvoju (*Jobling i Jamasb, 2017*).

[85] U skladu s Direktivom 2006/67/EC Unija svojim članicama nameće obvezu održavanja minimalnih zaliha nafte i/ili naftnih derivata. Kroz ovakve odredbe Unija čini opskrbu nafte sigurnijom za europske građane i u slučaju opasnosti osigurava dostupnost obveznih zaliha koje se mogu mobilizirati kada je to potrebno. To će pomoći ublažiti štetne posljedice, kao što su nestašice goriva i rast cijena, što su posljedice mogućeg poremećaja opskrbe. U RH Zakon o tržištu nafte i naftnih derivata (NN 19/2014) usklađen je s prethodno spomenutom Direktivom. U tom smislu, definirane su obvezne zalihe nafte i naftnih derivata koje se formiraju najmanje u količini od 90 dana prosječnog dnevnog neto uvoza ili 61 dan prosječne dnevne domaće potrošnje naftnih derivata u prethodnoj kalendarskoj godini, ovisno o tome koja je količina veća. Ovim se Zakonom povećava sigurnost opskrbe tržišta naftnih derivata kroz detaljno uređivanje obveze skladištenja operativnih rezervi naftnih derivata za što su odgovorni energetski subjekti. Energetski subjekti dužni su operativne zalihe skladištiti na teritoriju RH, a količine koje su dužni skladištiti moraju se podudarati s njihovim udjelom na tržištu.

2.3.3. Kretanje cijena nafte

Kao što je to slučaj i kod ostalih dobara, cijena nafte slijedi trendove u ponudi i potražnji na način da se povećanjem ponude cijena smanjuje (i obrnuto), odnosno povećanjem potražnje povećava (i obrnuto). Navedeno su fundamentalne dugoročne odrednice tržišta nafte zbog čega su prethodno detaljnije i analizirane. Ponašanje i uzroci promjena cijena nafte u fokusu su niza znanstvenih istraživanja (*cf. Balabanoff, 1995; Sadorsky, 2000; Lynch, 2002; Kaufmann et al., 2004; Moebert, 2007; Hamilton, 2008b; He et al., 2010; Baumeister i Kilian (2016), Golombek, 2018; Kim i Vera, 2018; Zavadska et al., 2018; Baumeister i Hamilton, 2019).* Razlog zbog kojeg je tako izazovno, i gotovo nemoguće, predvidjeti kretanje cijena nafte je činjenica da ono što se smatra globalnim naftnim tržištem u stvarnosti podrazumijeva više različitih tržišta (financijska tržišta, tržišta sirove nafte, tržišta naftnih derivata) koji funkcioniraju odvojeno ali među kojima postoji visok stupanj međuovisnosti, po principu povezanih posuda (*Carollo, 2012*).

Postoji više tipova (vrsta) nafte diljem svijeta koje karakteriziraju različite odlike, a klasificiraju se prema zemljopisnom položaju proizvodnje, specifičnoj težini (odnosno API gustoći) i udjelu sumpora[86], i poznati su kao pokazatelji cijena nafte (*engl. benchmark*) koji se koriste kao referentna mjerila globalnih cijena nafte. Karakteristike sirove nafte utječu i na njenu cijenu; što je manja API gustoća (tzv. lakša nafta) i manji udio sumpora, rafinerijski je proces jednostavniji i jeftiniji kao i transport naftovodima. Takva je nafta, samim time, skuplja. Vrijedi i obratno.

Iako postoji čak preko sto pedeset referentnih mjerila, najpoznatija tri su; West Texas Intermediate (WTI) kao referentni pokazatelj cijena nafte južne i (primarno) sjeverne Amerike, North Sea Brent[87], kao referentni pokazatelj cijena nafte za Europu i Dubai crude oil, kao referentni pokazatelj cijena nafte za Aziju. Grafikonom 2.3.3.1. usporedno je prikazano kretanje njihovih nominalnih vrijednosti u USD u periodu od 1976. do 2018. godine. Važno je istaknuti da navedeni grafikon prikazuje godišnje cijene, dok bi kod mjesečnih i tjednih podataka, a

[86] Klasifikacija različitih vrsta nafte, koja očigledno nije homogen proizvod, temelji se na specifičnoj težini i udjelu sumpora; svaka klasifikacija podrazumijeva i donekle drugačiju cijenu.
[87] Sam naziv Brent predstavlja akronim glavnih naftnih polja u Sjevernom moru (koja su, doduše, već poprilično iscrpljena).

posebno dnevnih, bilo i znatnijih odstupanja; niža vremenska frekvencija omogućava dulje vrijeme za međusobno usklađivanje cijena.

Grafikon 2.3.3.1.: Kretanje prosječnih godišnjih nominalnih (tekućih) cijena nafte u dolarima po barelu; WTI, Brent i Dubai, 1976.-2018.

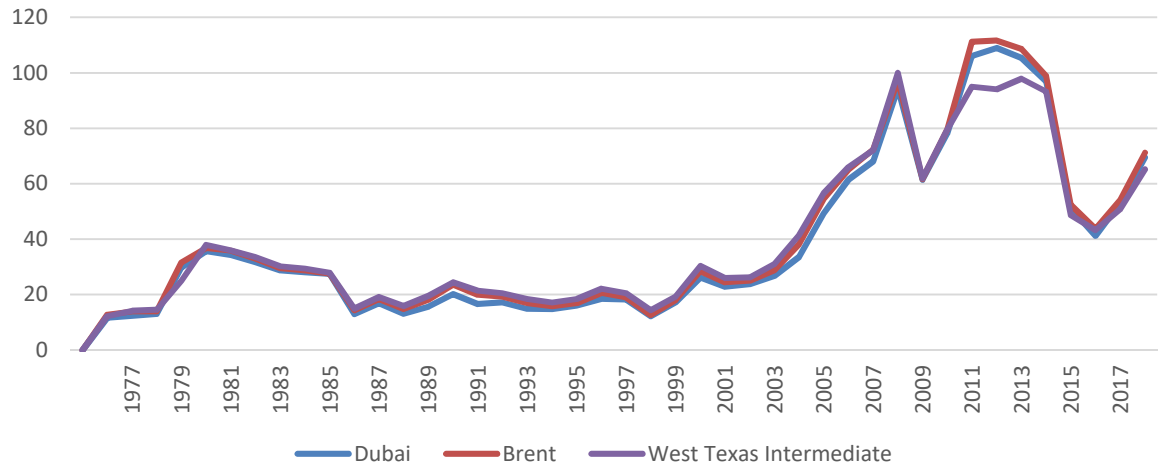

Izvor: British Petroleum, BP Statistical Review of World Energy 2018

Brent mjerilo koristi se za otprilike 67% globalne fizičke trgovine sirovom naftom (*Davis, 2012*). Zbog toga se uobičajeno koristi kao pokazatelj svjetske cijene nafte (za Europu i Afriku pogotovo; *Speight, 2017*), posebno nakon perioda od 2010. do 2014. kada je WTI imao znatno nižu cijenu te kao takav nije bio reprezentativan pokazatelj svjetske cijene nafte. U novije je vrijeme tako uobičajeno da se gotovo isključivo Brent[88] cijena nafte koristi kao referentni globalni pokazatelj *(Baumeister i Kilian, 2016).* Usporedbom kretanja cijena nafte za navedena tri geografska područja, evidentno je njihovo blisko kretanje (s iznimkom ranije navedenog perioda 2010-2014 kada je WTI bio niži) kao i znatan rast u posljednjih 20 godina. Ipak, kako je riječ o nominalnim cijenama nafte, precizniji uvid u prirodu kretanja cijena nafte nudi sljedeći grafikon kod kojeg je prikazana razlika realnih i nominalnih cijena nafte (Brent pokazatelja koji je korišten i u empirijskom dijelu ove disertacije).

Grafikonom 2.3.3.2. prikazano je povijesno kretanje nominalnih i realnih (u USD 2015.) Brent cijena nafte od 1861. do 2015. godine. Ujedno su vertikalnim isprekidanim linijama (koje

[88] Brent nafta je idealna za proizvodnju motornog benzina i srednjih destilata nafte, koji se uobičajeno i konzumiraju u sjevernoj Europi gdje ga se većina i rafinira. Dio Brent mješavine nafte rafinira se i u SAD-u kao i na Mediteranu (*Speight, 2017*).

predstavljaju strukturne lomove u prikazanim vremenskim nizovima) razdijeljene tri različite epohe kretanja cijena nafte (*Dvir i Rogoff, 2010; Jobling i Jamasb, 2017*).

Grafikon 2.3.3.2.: Povijesno kretanje realnih i nominalnih cijena nafte (1861.-2015.)*

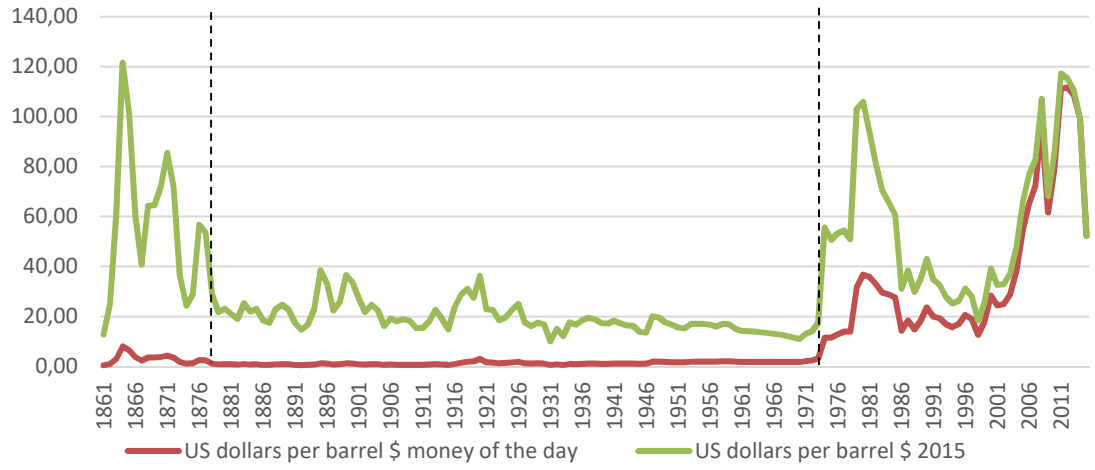

*1861-1944 US Average, 1945-1983 Arabian Light, 1984-2015 Brent dated, Nominalne cijene nafte deflacionirane su indeksom potrošačkih cijena SAD-a (US CPI, 2015=100)
Izvor: prema BP Statistical Review of World Energy 2016 - data workbook: Oil: Crude Oil prices, preuzeto sa: http://www.bp.com/en/global/corporate/energy-economics/statistical-review-of-world-energy.html (07/2016)

Prva je epoha okarakterizirana nestabilnim cijenama nafte i početcima komercijalne proizvodnje s prevladavajućom nestabilnom ponudom. Druga je epoha tzv. epoha jeftine nafte, stabilnih cijena i uspostave formalnog tržišta nafte. U sklopu treće epohe, u kojoj se još uvijek nalazimo, prevladavajuća karakteristika cijena nafte je njihova volatilnost. Ova je epoha obilježena naftnim šokovima. Upravo je njima, u kontekstu ovog (ali i drugih sličnih) istraživanja posvećen poseban interes[89]. Ne manje važno, u prethodnom dijelu rada (poglavlje 2.2.) analizirana istraživanja utjecaja cijena nafte na pojedine makroekonomske pokazatelje naglašavaju važnost uzroka naftnog šoka koji, prema istima, determinira i način utjecaja na svjetska gospodarstva. Zato je i samim uzrocima promjena cijena nafte posvećena pažnja uz napomenu da i po tom često manjka znanstvenog konsenzusa. Na ovome je mjestu stoga nužno analizirati dosadašnje naftne šokove s posebnim naglaskom na posljednji, onaj 2008., zbog vremenskog obuhvata ovog istraživanja.

[89] Detaljnu elaboraciju uzroka naftnih šokova (u širem kontekstu, posebno geopolitičkom) unutar posljednjih vidi kod *McNally (2017)*

2.3.3.1. Naftni šokovi

Breitenfellner et al. (2009) kao moguće uzroke naftnih šokova navode: 1) brzo rastuću potražnju kao odraz snažne globalne ekonomske aktivnosti, 2) pad ponude nafte ili očekivanja poremećaja u opskrbi naftom, 3) koordiniranu aktivnost proizvođača nafte i 4) špekulativno ponašanje sudionika na financijskim tržištima. Prema istim autorima, navedeni uzroci nisu međusobno isključivi, mogu biti komplementarni i/ili se kronološki izmjenjivati. Nadalje, kako je već i naznačeno u uvodnom dijelu, sve se više pažnje usmjerava na uzroke promjene cijena nafte argumentirajući da o istima ovide i njihovi efekti (smjer i jačina utjecaja) na makroekonomske pokazatelje gospodarstava.

Definicija naftnog šoka nalaže da je riječ o neočekivanom rastu cijena nafte (*Baumeister i Kilian, 2016*). Kako je moguće razabrati iz cijena predočenih Grafikonom 2.3.1.2., cijene su nafte bile relativno stabilne sve do početka 1970ih, kada dolazi do prvih naftnih šokova čime je znatno povećana volatilnost cijena nafte.

Početkom 1970ih globalno tržište nafte promijenilo svoju strukturu od konkurentnog prema kartelskom (*Krichene, 2002; Dvir i Rogoff, 2010; Alquist et al., 2013; Herrera et al., 2015*). U dotadašnjem periodu glavnu riječ su vodile međunarodne naftne kompanije (tzv. Sedam sestara), a potom dolazi do prebacivanja moći iz njihovih ruku u ruke zemalja izvoznica nafte (koje su počele podizati porez na svaki barel koji se proizvede na njihovom području). Paralelno s navedenim, koncem 1960ih i početkom 1970ih svjetsko je gospodarstvo bilo u periodu snažnog gospodarskog rasta (*McNally, 2017*), što je rezultiralo godišnjim stopama rasta potrošnje nafte od gotovo 10% (ujedno proizvodnja nafte u SAD-u doseže vrhunac 1972., *Hamilton, 2011*). Istovremeno, zemlje izvoznice sa Srednjeg istoka dolaze do maksimalnih kapaciteta proizvodnje. Saudijska Arabija i Kuvajt, koje su imale prostora za povećanje proizvodnje, nisu to učinile kao izraz negodovanja na ranije dogovorene (1971.) fiksne cijene nafte koje im sada više nisu bile zadovoljavajuće. Dotadašnja situacija na tržištu nafte gotovo uvijek je podrazumijevala višak ponude nafte (bez postojanja kartela nije bilo dogovora oko količina proizvodnje), no koncem 1960ih i početkom 1970ih ovaj raspon između ponude i potražnje za naftom drastično se smanjio. Sve navedeno je bilo podloga i uvertira za **prvi naftni šok** koji se dogodio 1973. godine. U listopadu 1973. godine Sirija i Egipat napale su Izrael (tzv. Yom Kippurski rat). Tom su prigodom SAD i mnoge zapadne ekonomije pružile podršku Izraelu na što su članice OPEC-a (arapski izvoznici i Iran) odgovorile uvođenjem embarga na

izvoz nafte istima. U istom mjesecu raskinuti su od strane arapskih izvoznica nafte ranije potpisani sporazumi o izvozu nafte po fiksnim cijenama (*engl. Teheran/Tripoli agreements*) te su izvoznice povisile cijene i smanjile količinu proizvodnje (*Baumeister i Kilian, 2016*). Panika i rezultirajuća nedostupnost nafte iz dotadašnjih dobavnih pravaca rezultirala je (u periodu od 1972. do 1974.) rastom realnih cijena nafte od preko 250% (*Kaufmann et al., 2008*). Ovaj je naftni šok obilježio kraj ere jeftine nafte.

U narednom periodu, od 1974. do 1978., cijene nafte bile su relativno stabilne. 1979. dolazi do **drugog naftnog šoka** koji je ovoga puta bio, prema mišljenju većine, posljedica Iranske revolucije (*Hamilton, 2003*). Iranska je revolucija rezultirala snažnim poremećajima u proizvodnji nafte. U periodu od rujna 1978. do siječnja 1979. Iranska proizvodnja je pala sa 6 na 0,4 milijuna barela nafte dnevno, što je podrazumijevalo pad globalne proizvodnje nafte od 9,1% (*Hamilton, 1985*). Iako su Saudijska Arabija i ostale članice OPEC-a mogle nadoknaditi iranske gubitke u proizvodnji, pad proizvodnje nafte od strane Irana (koji je u to vrijeme bio drugi najveći izvoznik) poljuljao je tržište nafte (*McNally, 2017*). Unatoč zalihama nafte kao i nepotpunoj iskorištenosti proizvodnih kapaciteta (prema *BP, Statistical Review of World Energy, 2016*), članice OPEC-a, posebno najznačajnija Saudijska Arabija, odbile su povećati proizvodnju kako bi se nadoknadili Iranski gubitci. Rezultat je bio eksplozija realne cijene nafte od preko 100% (*Adelman, 2002*)[90]. *Kilian (2009)* smatra da se tek dio rasta cijene nafte, kao i kod prethodnog naftnog šoka, može pojasniti reakcijama na strani ponude nafte, te da je snažan globalni rast odgovoran za gotovo dvije trećine ukupnog rasta cijene. Konačno, *Kilian i Murphy (2014)* navode važnost Iranske revolucije više u smislu utjecaja na očekivanja (negoli na ponudu), što je rezultiralo i snažnijim rastom zaliha u očekivanju daljnjih poremećaja opskrbe naftom.

Početkom 1980ih, nakon navedenih naftnih šokova, globalno se događaju važne promjene (*McNally, 2017*). Svjetska je potražnja nafte (od 1979. do 1984.) smanjena za gotovo 10%, a pad od gotovo 15% zabilježen je u zemljama OECD-a. Ovo je bio odraz recesije kao i prilagodbi na naftne šokove. Vlade zemalja uvoznica, kao i sami stanovnici, prilagođavaju svoje ponašanje

[90] Važno je naglasiti i pozadinu koja je podrazumijevala tadašnju obvezu članica OPEC-a da prodaju nafte po dogovorenim cijenama. Jačanjem spot tržišta, dolazi do situacije da kupci njihove nafte na spot tržištu preprodaju naftu po znatno višim cijenama od kupovne (jer je došlo do manjka ponude pa su i kupci spremni nuditi više cijene), a os straha od daljnjih nestašica raste i špekulativna potražnja. Kao posljedica članice OPEC-a su povećale prodaju nafte po višim cijenama kupcima s kojima nisu imale dogovorene cijene, a potom su i podigle administrativne cijene po barelu. U konačnici je Saudijska Arabija smanjila proizvodnju nafte (*McNally, 2017*).

novonastalim uvjetima kako bi minimizirali svoju podložnost naftnim šokovima; uvode se porezi, potrošnja energije pada zbog strukturnih prilagodbi proizvodnje i potrošnje (supstituira se nafta jeftinijim dostupnijim energentima), smanjuje se energetska intenzivnost i raste energetska učinkovitost. Naftni su šokovi ponukali i investicije u sektor koje su rezultirale rastom ponude nafte izvan OPEC-a (odnosno, globalnim viškom ponude koja je obarala cijene nafte). Konačno, jačanjem spot tržišta, tržišna moć se prebacuje sa strane ponude na stranu potražnje (kupaca), a što je bilo vidljivo padom spot cijena nafte ispod administrativnih (OPEC cijena). Tržišni je udio OPEC-a tako pao sa 53% 1973. na 43% 1980, odnosno na svega 28% 1985. (*Baumeister i Kilian, 2016).*

Period **trećeg naftnog šoka** obilježen je invazijom Iraka na Kuvajt koncem 1990. Iako je došlo do znatnih poremećaja u količini proizvodnje zaraćenih strana, *Kilian i Murphy (2014)* naglašavaju kako je stvarni utjecaj na rast cijene nafte imala špekulativna potražnja za naftom zbog očekivanja napada na Saudijsku Arabiju (koja je najveći proizvođač) i straha od daljnjih poremećaja u proizvodnji. Tek koncem 1990., kada je SAD vojnim trupama osigurao Saudijsku Arabiju od moguće invazije na njen teritorij, cijene nafte su drastično pale. Unatoč rastu nominalne (i realne) cijene nafte za više od 50% (od 1988. do 1990.), navedeni naftni šok nije bio jak kao prethodna dva. U širem periodu od 1986. do 1999. nominalne su cijene nafte bile relativno stabilne, iako volatilnije u odnosu na druge robe (*Adelman, 2002*), a realne su cijene nafte čak pokazale i blagi opadajući trend (*Krichene, 2002*).

Važno je naglasiti da se veliki naftni šokovi dvadesetog stoljeća generalno smatraju posljedicama prvenstveno poremećaja na strani ponude kao i geopolitičkih previranja (posebno na Srednjem Istoku, *Hamilton, 2003*) pri čemu se, kako je navedeno, u novije vrijeme javljaju ponešto drugačija viđenja.

Četvrti naftni šok, 2008. godine, obilježen je do tada je u povijesti nezabilježenim snažnim rastom cijena nafte, sa 28 USD (2003. godine) na 134 USD 2008. Štoviše, po pitanju uzroka koji su doveli do ovog snažnog rasta cijena, čak se i akademska zajednica slaže da isti nije posljedica samo poremećaja na strani ponude nafte, već postupnih manjih šokova na strani potražnje za naftom (*Hamilton, 2009*; *Baumeister i Kilian, 2016).*

Za razliku od prethodnih triju naftnih šokova koji su rezultirali stagflacijskim krizama, makroekonomske posljedice ovog rasta nafte bile su iznimno blage sve do konca 2007. godine

(*Breitenfeller et al., 2009*). Između ostalih, *Kilian (2008a), Hamilton (2009)*, *Aasteveit et al. (2012)*, *Cantore et al. (2012)*, *Kilian i Hicks (2013)* i *Kilian i Murphy (2014)* pojašnjavaju navedene skokove u potražnji nepredvidivom (neočekivanom) ekspanzijom globalne ekonomije potaknutom prvenstveno snažnim rastom azijskih ekonomija (Kine i Indije). *Aasteveit et al. (2012)* tako procjenjuju da je doprinos potražnje iz zemalja u razvoju bio čak 55 USD (u realnim terminima), te da bi efekt bio i jači da istovremeno nije došlo do pada potražnje za naftom u razvijenim zemljama. *Ratti i Vespignani (2013)* navode da je znatan rast likvidnosti u Indiji i Kini također doprinio rastu realnih cijena nafte. Unatoč navedenom prevladavajućem stavu akademske zajednice, mogu se naći i pojašnjenja koja govore u korist špekulacija kao izvora navedenog naftnog šoka (*cf. Fattouh et al., 2013*). *Hamilton (2009)* tako pripisuje naftni šok iz 2008. godine prvenstveno snažnom rastu potražnje (primarno iz Kine), špekulacijama na naftnim tržištima, odgodama kao i geološkim ograničenjima u proizvodnji nafte te OPEC-ovom (monopolističkom) postavljanju cijena.

Nužno je naglasiti da promjene potražnje za naftom imaju izraženije amplitude od kretanja BDP-a koji se u velikoj mjeri sastoji od, sporo reagirajuće, osobne potrošnje. Kako je svjetska financijska kriza imala prilično heterogen utjecaj na različite svjetske ekonomije, u 2009. dolazi do oporavka potražnje za naftom (ponovno od strane azijskih ekonomija) što ubrzo vraća cijenu nafte iznad 100 USD gdje se, zahvaljujući nekolicini manjih šokova na strani ponude i potražnje[91], ista i zadržala sve do 2014. godine (*Baumeister i Kilian, 2016)*. Od lipnja 2014. do siječnja 2015. Brent cijena nafte strmoglavila se sa 112 USD na svega 47 USD ponovno kao odraz interakcije nekoliko faktora na tržištu nafte; prvenstveno pada globalne ekonomske aktivnosti, šokova na strani proizvodnje nafte (rast proizvodnje od strane SAD-a), očekivanja daljnjeg pada cijena nafte koja su smanjila trenutne zalihe, kao i daljnje neočekivano usporavanje svjetske ekonomije koncem 2014. (*Baumeister i Kilian, 2015*). Mnogi također navode i da je kap koja je prelila čašu bila sastanak OPEC-a koncem 2014. gdje nisu najavili rezanje proizvodnje unatoč stabilnoj rastućoj ponudi nafte izvan OPEC-a (*Khan et al., 2017*).

Kako je i razvidno iz prethodno naznačenih uzroka dosadašnjih naftnih šokova, nisu svi naftni šokovi isti. Ne manje važno, novija istraživanja upućuju i na zaključak o endogenosti cijena nafte koje svojom visinom reagiraju na globalnu ekonomsku aktivnost. Recentna demonstracija

[91] Libijska kriza 2011., tenzije u Iranu 2012., snažan rast proizvodnje u SAD-u, među ostalim.

ovog odnosa je i ona iz 2008. kada je svjetska kriza, zbog drastičnog pada potražnje, oborila i cijene nafte (*Baumeister i Kilian, 2016*). Tako niz autora, počevši primarno od *Kiliana (2008b)*, razlučuje različite vrste naftnih šokova s obzirom na njihov uzrok (*cf. Kilian i Lee, 2014; Baumeister i Kilian, 2015; Cunado et al., 2015; Kilian, 2017; Antolin-Diaz i Rubio-Ramirez, 2018; Herrera i Rangaraju, 2018*). Tako se prilikom istraživanja modeliraju strukturni šokovi ovisno o smjeru kretanja triju ključnih veličina (na globalnoj razini): količine proizvodnje nafte (Q_{oil}), cijena nafte (P_{oil}) i realni gospodarski rast (Y_w). Kako je prikazano Tablicom 2.3.3.1.1., različite vrste naftnih šokova uključuju šokove na strani ponude (*engl. oil-supply shocks*), šokove na strani potražnje koji se javljaju kao posljedica gospodarske aktivnosti (*engl. oil-demand shocks driven by global economic activity*) i šokove na strani potražnje koji su vođeni očekivanjima o budućim cijenama nafte, tj. špekulacijama (*engl. oil-specific demand shocks*).

Tablica 2.3.3.1.1. Identifikacija strukture naftnih šokova s obzirom na izvor promjene cijene

Strukturni naftni šokovi	Q_{oil}	P_{oil}	Y_w
Šok na strani ponude	< 0	> 0	≤ 0
Šok na strani potražnje kao posljedica snažne gospodarske aktivnosti	> 0	> 0	> 0
Šok na strani potražnje vođen očekivanjima o budućim cijenama nafte	> 0	> 0	≤ 0

Izvor: obrada autorice prema *Baumeister, Peersman i Van Robays (2009)*

Restrikcije prikazane tablicom utemeljene su na fundamentalnim odrednicama tržišta nafte (ranije iznesenim kroz ovo podpoglavlje). Šok na strani ponude rezultat je poremećaja u ponudi tržišta naftom koje nastaju kao rezultat npr. djelovanja OPEC-a ili vojnih akcija na teritorijima zemalja izvoznica nafte. Šok na strani potražnje kao posljedica snažne gospodarske aktivnosti rezultat je snažne potražnje za naftom potaknute snažnom globalnom ekonomskom aktivnošću što povećava njene cijene. Zbog navedenog se potražnja za naftom i njena cijena kreću iu istom smjeru. Konačno, šok na strani potražnje vođen očekivanjima o budućim cijenama nafte podrazumijeva špekulativne izvore naftnih šokova zbog čega isti djeluju pozitivno na cijenu nafte dok na realni gospodarski rast nemaju učinak ili je isti negativan.

Evidentno je da je globalno tržište nafte izuzetno kompleksno pa se u pojedinim slučajevima niti sa znatnim vremenskim odmakom ne mogu točno detektirati uzroci promjena cijena nafte. Ovo je izuzetno važno jer pojedina istraživanja (*Kiliana, 2009; Cashin et al., 2014; Cunado et*

al., 2015; Cross i Nguyen, 2017) ističu da način na koji naftni šok utječe na gospodarstvo, između ostalog, ovisi o samim uzrocima istog. Na istom tragu i *Archanskaïa et al. (2012)* navode rezultate koji potvrđuju razlike u prirodi dosadašnjih naftnih šokova ističući pri tom uvažavanje uzroka naftnih šokova pri odabiru adekvatnih mjera monetarne i fiskalne politike.

Konačno, sama priroda naftnog šoka može biti i potencijalno pojašnjenje asimetrične reakcije gospodarstva na cijene nafte. Pad cijena nafte uzrokovan viškovima ponude iste nikako neće imati isti utjecaj na gospodarstvo kao i pad cijena nafte koji je posljedica drastičnog pada potražnje. Pad cijena nafte iz potonjeg slučaja neće imati gotovo nikakve pozitivne učinke na gospodarstvo (*Ullrich, 2015*).

2.3.3.2. Volatilnost cijena nafte

Volatilnost (promjenjivost) cijena nafte uobičajeno se definira kao standardna devijacija cijena nafte u promatranom periodu (*Ebrahim et al., 2014*). Za razliku od ostalih dobara, nafta nije uobičajena roba jer njene cijene pokazuju znatno veću cjenovnu volatilnost od ostalih vrsta roba (*Cashin i McDermott, 2002; Regnier, 2007; Ebrahim et al., 2014*). Tome pridonosi činjenica da je nafta globalno najznačajnija roba (u trgovinskom smislu), politički motivi koji gotovo svakodnevno utječu na cijenu nafte (ili to pokušavaju), kao i činjenica da se njena proizvodnja odvija na nesavršenom tržištu zbog postojanja i utjecaja OPEC-a na ponudu, kao i sve snažnije konkurencije izvan njega (SAD, Kanada, Rusija). Ovome valja dodati i ulogu dokazanih rezervi koje, kao i količina proizvodnje nafte, rastu zahvaljujući iznimnom tehnološkom napretku kao i rastu cijena nafte, ali i ulozi zaliha nafte (inventarnih)[92] koje reagiraju na promjene cijena nafte te ujedno podstiču njihovu volatilnost (špekulativnim djelovanjem na spot i futures tržištima). Visoke cijene nafte potaknule su investicije u naftni sektor zahvaljujući kojima je došlo do iznimnih tehnoloških otkrića. Ovime je omogućeno preciznije mjerenje rezervi nafte, ali i (uz povećane cijene ekonomski isplativu) ekstrakcija nafte iz tzv. nekonvencionalnih izvora: naftonosnog škriljevca (*engl. shale oil*), naftnog pijeska (*engl. oil sands*) i bušotina na velikim morskim dubinama (*engl. deep-water drilling*) (*Rubin, 2012*), dok se offshore bušotine u Arktičkom pojasu trenutno smatraju krajnjom tehnološkom (i najskupljom) granicom proizvodnje nafte (*IEA, 2010b*).

[92] U prvom desetljeću trećeg milenija globalne dokazane rezerve povećale su se za čak 26% (*BP, Statistical Review of World Energy, 2016*)

Uzevši u obzir iznimnu važnost nafte u gospodarstvu, stabilnost njenih cijena iznimno je važna. Rast volatilnosti cijena nafte uzrokuje i veću neizvjesnost glede budućih cijena što vodi ekonomskoj nestabilnosti zemlje, bilo da je ista uvoznik ili izvoznik nafte (*Narayan i Narayan, 2007*). Turbulencije na naftnim tržištima brzo se pretaču u industrijske i komercijalne sektore koji ovise o stabilnom priljevu nafte po prihvatljivim cijenama (*McNally, 2017*). Nositeljima monetarne i fiskalne politike volatilnost cijena nafte također predstavlja izazov. Reakcije gospodarstva na volatilnost nafte upućuju na destabilizacijske makroekonomske posljedice koje (s obzirom na nepostojanje cjenovno dostupne alternative u bliskoj budućnosti) predstavljaju ograničenje održivom razvoju (*Ebrahim et al., 2014).* U znatno većoj mjeri u odnosu na ostale robe, nafta je ključni faktor u međunarodnoj politici, kao i daleko najviše globalno razmjenjivano dobro, a porezi i trošarine na naftne derivate čine ključan izvor proračunskih prihoda za gotovo stotinu zemalja svijeta (*Tordo et al., 2011*). Sve navedeno potencira važnost stabilnosti cijena nafte (kao i problem njihove volatilnosti) koja je u novijoj povijesti narušena, posebice u trećem mileniju (*Ebrahim et al., 2014*).

Rast cijena nafte, kao i rast volatilnosti cijena nafte, posebice u protekla dva desetljeća (ili u trećoj epohi cijena nafte kako je prethodno isticano), nagnali su akademske krugove na širi pristup istraživanju čimbenika koji bi mogli rezultirati ovakvim reakcijama na tržištu, posebno u kratkom roku.

Prema podacima ranije prikazanim Grafikonom 2.3.1.2., u periodu od 1947. do 1985. cijene nafte uglavnom su rasle, no počevši od 1986. godine naovamo, uzorak ponašanja cijena nafte se mijenja. Prisutna su značajna povećanja i smanjenja cijene nafte kao i porast volatilnosti njihovih cijena (*Hamilton, 2008*). *Lee et al. (1995)* i *Hooker (1996)* u svojim radovima dovode po prvi puta u pitanje *Hamiltonovu (1983)* široko prihvaćenu teoriju o statistički značajnoj negativnoj korelaciji između cijena nafte i razine outputa, te tvrde da spomenuta relacija gubi svoju jačinu kada se uzmu u obzir duže vremenske serije. Kako je malo vjerojatno da cijene tako važnog energenta nemaju nikakav utjecaj na gospodarstvo, evidentno se priroda te relacije promijenila, kako je već istaknuto u prethodnim dijelovima ove disertacije. Sukladno tome, *Lee et al. (1995)* i *Hooker (1996)* tvrde da je neophodno uzeti u obzir i volatilnost cijena (pored njihove razine). *Hamilton (1996)* revidirajući svoja istraživanja na dužim vremenskim serijama podataka spoznaje istinitost *Hookerovih (1996)* tvrdnji, te uvodi novu varijablu (NOPI) koja ponovno pokazuje značajan utjecaj na razinu outputa. *Hooker (1996)* također ističe i neprimjenjivost cjenovne asimetrije koju koristi *Mork (1989)* te jasno i nepobitno naglašava

nepouzdanost korištenja razine cijena nafte u makroekonomskim analizama podataka od 1986. godine naovamo. U skladu s navedenim istraživanjima mogu se pronaći i potvrde važnosti volatilnosti cijena nafte u recentnijim analizama utjecaja cijena nafte na gospodarstvo (*cf. Guo i Kliesen, 2005; Rafiq et al., 2009; Bredin et al., 2010; Elder i Serletis, 2010; Jo, 2012; Bilgin et al., 2015; Elder, 2018*).

Sukladno navedenim argumentima, u literaturi se mogu pronaći i sljedeća pojašnjenja volatilnosti cijena nafte u novijoj povijesti. Za razliku od realnih cijena nafte koje, prema znanstvenom konsenzusu, u dugom roku ovise primarno o kretanjima ponude i potražnje (jer se iste u kratkom roku ne mogu drastično mijenjati[93]), u kratkom roku, pored geopolitičkih previranja koja mogu poremetiti dobavne pravce, utjecaj na cijene nafte i njihovu volatilnost imaju zalihe nafte (inventarne) kao i špekulacije. Špekulacije su, naravno, opet vezane za zalihe nafte jer podrazumijevaju kupnju u sadašnjem trenutku s ciljem budućeg korištenja/preprodaje.

Tržište nafte karakterizira izrazito niska elastičnost ponude, zbog čega bilo kakav snažniji porast potražnje ne može biti popraćen jednakim rastom ponude, barem ne u kratkom roku. *Fattouh (2007a)* stoga zaključuje da su, u odsutnosti adekvatnih količina uskladištenih zaliha nafte, jedini mehanizam čišćenja tržišta snažne cjenovne reakcije. Iz danih ograničenja (ponude) proizlazi i sljedeća spoznaja o dinamici cijena: ubrzan rast prosječne razine cijena te učestalije i dramatičnije promjene cijena rezultiraju porastom volatilnosti.

Konvencionalno stajalište nalaže da povećanje komercijalnih rezervi nafte smanjuje cijene na tržištu jer se ono tumači kao postojanje viška ponude na tržištu (viška koji se, dakle, uklanja skladištenjem za buduću potrošnju). *Morse (2006)* ističe da su sada trendovi nešto drugačiji jer se komercijalne zalihe povećavaju usporedno s rastom cijene nafte. Smatra se da glavni razlog za ovakvu promjenu leži u smanjenju kapaciteta za skladištenje nafte zemalja izvoznica pa se povećavaju komercijalne zalihe kao instrument osiguranja. Ono što je također iznimno važno je uloga očekivanja koja znatno može narušiti navedene odnose. Očekivanja budućih manjkova ponude nafte (u odnosu na potrebno) kao i daljnjeg rasta njenih cijena rezultirat će rastom zaliha nafte kao i daljnjim pritiskom na rast njenih cijena (*Hamilton, 2009; Alquist i Kilian, 2010; Kilian i Murphy, 2014*), uz uvjet da je cjenovna elastičnost potražnje za naftom različita od

[93] Izuzev situacije kada proizvođači nafte rade znatno smanjenim kapacitetima što je u stvarnosti iznimno rijedak slučaj pa ni ne preostaje puno prostora za brzu prilagodbu ponude nafte.

nule. Čišćenje tržišta i u ovom se slučaju odvija putem pozitivnih cjenovnih reakcija na povećanu potražnju.

U teoriji, kako i spot i futures cijene odražavaju cijene iste robe (u ovom slučaju nafte) futures cijene ne bi smjele ovisiti o spot cijenama, niti ih određivati. Ipak, empirijski dokazi se razlikuju, i kao posljedica većina studija upućuje na to da se utjecaj među spomenutim cijenama kreće u smjeru od futures prema spot cijenama. Učestala racionalizacija ovakvih rezultata krije se u tome da futures cijene reagiraju na nove informacije puno brže od spot cijena, prvenstveno zbog nižih transakcijskih troškova i fleksibilnosti kratkog roka za ostvarenje kupoprodaje (*Bekiros i Diks, 2008*). U slučaju tržišta nafte to znači da suočen sa saznanjem o, primjerice, odluci OPEC-a o rezanju proizvodnje, špekulant ima mogućnost kupnje nafte na spot ili futures tržištu. Dok kupnja na spot tržištu zahtijeva veći inicijalni trošak i može potrajati neko vrijeme (najčešće dan-dva), sklapanje futures ugovora može se realizirati odmah, bez posjedovanja novca u trenutku prodaje, i bez ikakve brige o fizičkoj robi. *Silvapulle i Moosa (1999)* tako zaključuju da će spot cijene reagirati s vremenskim odmakom jer se spot transakcije ne mogu realizirati jednako brzo kao futures transakcije.

Valja istaknuti da pojedine studije ukazuju i na suprotan smjer utjecaja spot i futures cijena, a poznati su i slučajevi dvosmjernog utjecaja. *Kaufmann i Ullman (2009)* su pokušali ispitati s kojeg (spot/futures) tržišta dolaze cjenovne „inovacije“ na svjetsko tržište nafte. Zaključuju, sukladno rezultatima, da su promjene svjetskih cijena nafte generirane kako od strane promjena na fizičkom tržištu nafte, tako i od strane špekulanata.

Hipoteza prema kojoj futures cijene predvode spot cijene, u terminima postojećih empirijskih dokaza, čini se prihvatljivija. Ipak, s aspekta utjecaja na gospodarstvo puno je važnija uloga zaliha koje mogu amortizirati naftne šokove, ali i, kako je navedeno, ovisno o očekivanjima, poremetiti odnose ponude i potražnje na tržištu. Na tom tragu, *Alquist i Gervais (2013) i Kilian i Murphy (2014)* zaključuju da su u periodu od 2003. do 2008. cijene nafte bile primarno pod utjecajem snažne globalne potražnje, a ne kretanja inventarnih zaliha. Ipak, *Kilian i Murphy (2014),* proučavajući međuodnos zaliha nafte i špekulativnih transakcija istom, navode da je uloga zaliha bila značajnija u ranijim naftnim šokovima 1979. kao i 1990./1991. U konačnici je važno naznačiti da se sva istraživanja koja kao varijablu uključuju zalihe nafte suočavaju s ograničenjima dostupnosti podataka, a relativno nepoznate strateške rezerve izvan OECD-a, posebno u Kini, za koje se smatra da su povećane (posebno nakon posljednjeg naftnog šoka)

mogu znatno narušiti postavke pa i zaključke postojećih studija. Ništa manje važno, špekulativnu je potražnju teško kvantificirati jer, kako navode *Fattouh et al. (2013)*, špekulativnom se potražnjom smatra svaka kupnja nafte koja nije namijenjena za trenutnu potrošnju, što uvelike odudara od financijskih kategorija špekulanata[94].

Na samom koncu nužno je istaknuti, kako je iz iznijetog sadržaja poglavlja i vidljivo, da je svjetsko tržište nafte izrazito kompleksan mehanizam unutar kojeg se vrlo često tek uz iznimne napore mogu detektirati razlozi promjena svjetskih cijena nafte. Navedeno dodatno potencira poteškoće s kojima se suočavaju nositelji monetarne i fiskalne politike zemalja koje su pod utjecajem naftnih šokova jer brzina, ali i način njihove reakcije ovisni o jačini naftnog šoka i njegovom izvoru, koji, kako je prikazano, nije uvijek jasan. Kompleksnost uvjeta u kojima nositelji politike, ali jednako tako i poduzetnici, investitori te sami građani moraju donositi odluke otegotna je okolnost koja nerijetko ne ovisi samo o činjenicama, već i o očekivanjima istih. Sve navedeno ide u prilog potrebi da se utjecaj cijena nafte na pojedine makroekonomske pokazatelje, primarno inflaciju koja u pravilu najbrže reagira na naftni šok, sustavno istražuje na razini pojedinog gospodarstva i to uzimajući u obzir različite ulazne pokazatelje cijena nafte, pristupe, metode i vremenske obuhvate podataka kako bi se osigurala što kvalitetnija podloga za donošenje odluka.

[94] Za detaljniju analizu problema definiranja špekulanata na naftnim tržištima *cf. Alquist i Gervais (2013).*

3. ANALIZA MAKROEKONOMSKIH POKAZATELJA HRVATSKOG GOSPODARSTVA

Istraživanje utjecaja cijena nafte na makroekonomske pokazatelje hrvatskog gospodarstva zahtijeva i prethodnu analizu njihova kretanja u periodu empirijske analize ove doktorske disertacije (1995.-2015.). Kako bi se dobio cjeloviti uvid u gospodarske karakteristike nacionalnog gospodarstva, a imajući u vidu prethodno iznesene postavke istraživanja, kao i pregled dosadašnjih teorijskih i empirijskih saznanja, u ovom je poglavlju dana analiza kretanja BDP-a, inflacije, nezaposlenosti, kao i osobne i investicijske potrošnje. Koncem pojedinog potpoglavlja navedeni su i zaključci postojećih istraživanja o utjecaju cijena nafte na analizirane pokazatelje u RH (ako postoje). Konačno, analizirano je i tržište naftnih derivata u RH imajući u vidu činjenicu da se nafta u konačnici ne troši u njenom izvornom (nerafiniranom) obliku, već da je riječ o izvedenoj potražnji za njenim derivatima. U ovom je segmentu poseban osvrt dan na kretanje i strukturu cijena naftnih derivata.

3.1. BRUTO DOMAĆI PROIZVOD KAO INDIKATOR REALNOG GOSPODARSKOG RASTA

BDP predstavlja ukupnu vrijednost finalnih proizvoda i usluga stvorenih unutar granica jedne zemlje tijekom danog razdoblja (*Blanchard, 2005, str. 22*). Promatrajući kretanje hrvatskog realnog godišnjeg BDP-a[95] od 1995. do 2015. godine, analizom se može izdvojiti nekoliko perioda:

- rast BDP-a od 1996. do 2008. s iznimkom 1999. godine,
- pad BDP-a od 2009. do 2014. i
- gospodarski oporavak od 2015.

Zbog metodoloških razlika, dostupni podaci o realnom BDP-u u periodu do 1995. neusporedivi su s kasnijim podacima. Raspadom SFR Jugoslavije, u čijem je sastavu RH egzistirala do proglašenja samostalnosti 1991., prve godine samostalnosti (rane 1990e godine prošlog

[95] Nominalni BDP korigiran za inflaciju. U analizi je korišten BDP po rashodnoj metodi. Nužan preduvjet za međunarodnu usporedbu kretanja BDP-a, koji je prilikom provedbe ove analize zadovoljen, je i istovjetan metodološki pristup izračunu BDP-a.

stoljeća) obilježene su ratnim zbivanjima, ogromnim materijalnim štetama[96] i ljudskim žrtvama, kao i gubitkom tržišta zemalja bivše Jugoslavije. Slijedom navedenih zbivanja dogodio se i drastičan pad realnog BDP-a. Tako su, promatrajući posljednje desetljeće 20. stoljeća, u razdoblju od 1991. do 1995. koncentrirani nepovoljni makroekonomski trendovi (*Družić, 2004, str. 189*)[97].

Kretanje godišnje razine i stopa rasta realnog BDP-a u periodu od 1995. do 2015. godine prikazano je Grafikonom 3.1.1.

Grafikon 3.1.1.: Realne godišnje razine i stope rasta BDP-a*, 1995.-2015.

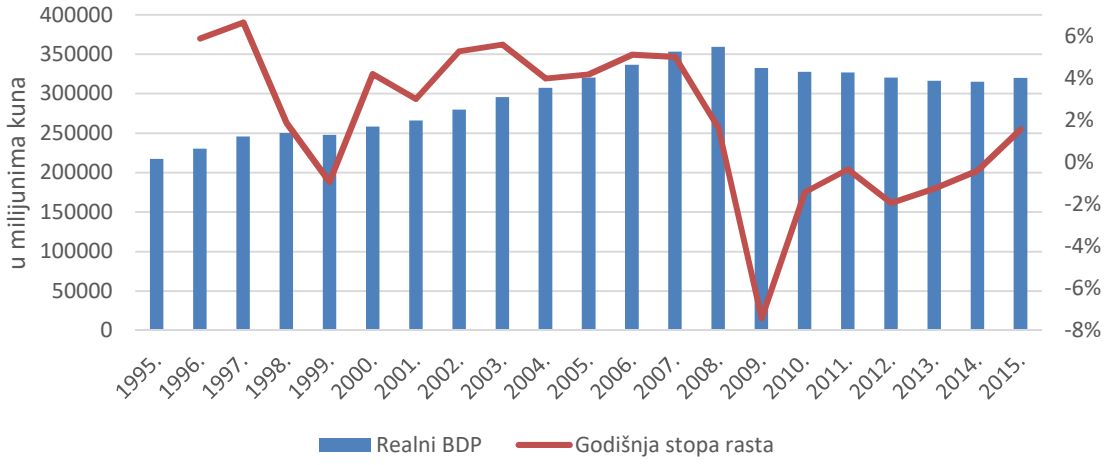

*BDP, godišnji u stalnim cijenama, referentna godina 2010, obračun po rashodnoj metodi
Izvor: Obrada autorice prema podacima DZS (2017a)[98]

U periodu od 1995. do 2008 ostvaren je realni gospodarski rast s izuzetkom 1999. godine[99]. Prosječne godišnje stope rasta realnog BDP-a bile su relativno visoke (već od 1994.) do 1999. godine, i to ponajprije zahvaljujući niskoj ekonomskoj bazi. Ipak, rast u drugoj polovini 1990ih nije uspio nadoknaditi gubitke tranzicije i Domovinskog rata (*Čavrak et al., 2011*). Tako i *Veselica i Vojnić, (2001*) navode da Hrvatska ni koncem 1990ih još uvijek nije dosegnula

[96] Prema podacima Državne revizije za popis i procjenu ratne štete, izravna ratna šteta u Hrvatskoj u razdoblju 1990.–1999. godine je iznosila 236.431.568.000 kuna ili 65.350.635.000 DEM *(Perković i Puljiz, 2001).*
[97] Za više detalja o procesu tranzicije (i posljedicama istog) u Hrvatskoj vidi u: *Družić (1998),* Tržišno restrukturiranje i privatizacija hrvatskog gospodarstva (str. 110.-134.).
[98] Godišnji podaci o realnom BDP-u i njegovim komponentama po rashodnoj metodi (osobna i državna potrošnja, bruto investicije u fiksni kapital, te uvoz i izvoz roba i usluga) korišteni u poglavlju 3. Analiza makroekonomskih pokazatelja hrvatskog gospodarstva preuzeti su sa stranica DZS (*2018a*).
[99] 1999. Hrvatska se našla u recesiji uzrokovanoj, s jedne strane, neriješenim strukturnim problemima gospodarstva, od privatizacije i restrukturiranja poduzeća do neadekvatne i sve lošije strukture javne potrošnje, a, s druge strane, drugom bankovnom krizom (u kojoj je došlo do bankrota i odlaska s tržišta nekoliko srednjih i malih depozitnih institucija), kosovskom krizom (koja se nepovoljno odrazila na prihode od turizma) i relativno slabim rastom u zemljama glavnim vanjskotrgovinskim partnerima Hrvatske (*HNB, Godišnje izvješće, 1999*).

predtranzicijsku razinu BDP-a što se ne može pripisati isključivo ratnim stradanjima, već i ekonomskim i socijalnim deformacijama izazvanim krivim privatizacijskim modelom, te pogrešnom politikom stabilizacije koja je produbila recesiju.

Rast realnog BDP-a od 65,6% (u razdoblju od 1996. do 2008. godine) s obzirom na nisku bazu iz 1996. i nije pretjerano velik, štoviše, on je umjeren i ispodprosječan u odnosu na zemlje EU10[100] gdje je prosječan realni rast iznosio 82% (*HGK, 2017a)*. Razdoblje od 2000. do 2008. godine ponovo obilježava znatan rast BDP-a, uz prosječnu stopu od 4,25%. 2004. godine, konačno, Hrvatska doseže razinu realnog BDP-a iz predratne 1990. godine (*Družić, 2005, str. 112.*). Za Hrvatsku je to razdoblje obilježeno izraženijim utjecajem rasta domaće potražnje na rast BDP-a. Nužno je istaknuti izrazito visok pozitivan utjecaj kreditne aktivnosti na kretanje domaće potražnje, a time i na rast BDP-a. Zanemari li se činjenica da su sve zemlje EU10 tijekom promatranog razdoblja postale članice EU, sve su manje razvijene zemlje EU10 rast u navedenom razdoblju pretežno temeljile na rastu domaće potražnje, dok su razvijenije EU10 zemlje rast više temeljile na izvozu roba i usluga (*HGK, 2017a*). U prilog iznesenom govore i podaci prikazani Grafikonom 3.1.2., o značajnom pozitivnom doprinosu domaće i negativnom doprinosu neto inozemne potražnje realnom rastu hrvatskog BDP-a sve do početka krize. Početkom krize, koncem 2008. godine, pad domaće potražnje podržavao je negativne realne stope rasta, naspram inozemne potražnje čiji je doprinos u periodu krize (s izuzetkom 2011. i 2013.) poprimio pozitivan predznak.

Grafikon 3.1.2.: Doprinosi domaće i neto inozemne potražnje rastu BDP-a, 1998.-2015. (u %)

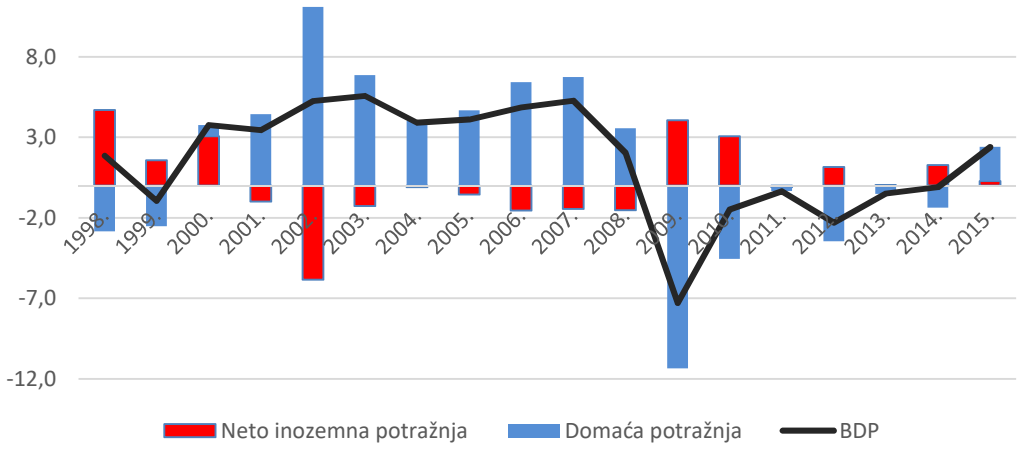

[100] Bugarska, Češka, Estonija, Latvija, Litva, Mađarska, Slovačka, Slovenija, Poljska, Rumunjska

Izvor: HNB, Doprinosi domaće i neto inozemne potražnje rastu BDP-a (2018a)

Prvi utjecaj globalne financijske krize (2008.) raširio se financijskim tržištima zajedno s povećanjem nesklonosti prema riziku, što je povećalo troškove inozemnog zaduživanja (*Bokan et al., 2010*). Suočena s rastućim troškovima zaduživanja, gospodarska aktivnost u Hrvatskoj počela je usporavati već sredinom 2008., a početkom 2009. započelo je razdoblje velike recesije na godišnjoj razini. U razdoblju od 2009. do 2014. kriza je potencirala slabosti hrvatskoga gospodarstva što je rezultiralo šestogodišnjim padom BDP-a. Hrvatska je, nažalost, bila među članicama EU koje su tijekom ovog razdoblja zabilježile najveći realni gospodarski pad[101]. U Hrvatskoj je u razdoblju od 2009. do 2014. zabilježen realni pad BDP-a od 12,6% što je i najveći pad u odnosu na EU10 *(HGK, 2017a)*.

Koncem (posljednje tromjesečje) 2014. hrvatsko gospodarstvo počinje davati znakove izlaska iz krize. U periodu od 2015. nadalje započinje gospodarski oporavak. Rast BDP-a od 6% od početka 2014. do konca 2015. svakako je dobrodošao, ali hrvatski realni BDP početkom 2016. još uvijek nije bio ni blizu predkrizne razine.

U konačnici, važno je usporediti i kretanje realnog BDP-a u odnosu na kretanje cijena nafte, a što je prikazano Grafikonom 3.1.3.

Grafikon 3.1.3.: Realne godišnje razine BDP-a (u cijenama 2010.) i godišnje realne cijene nafte*

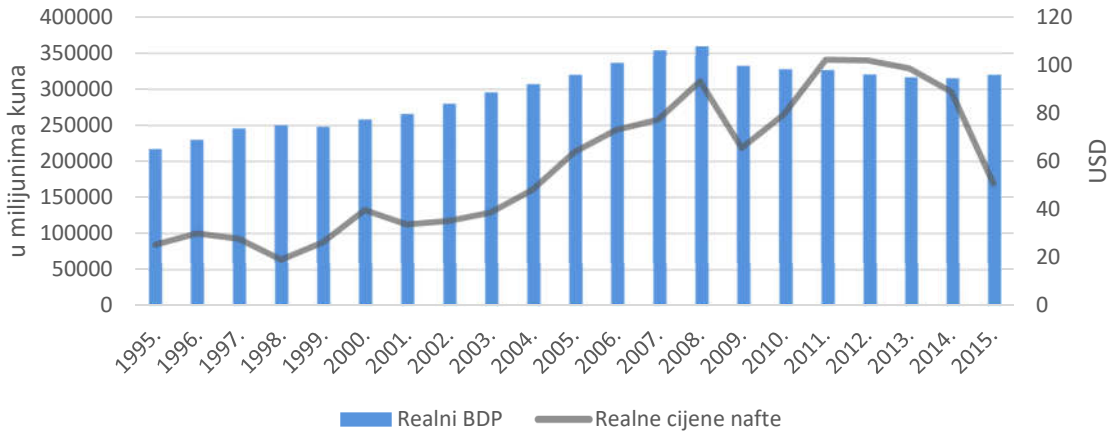

*Realne cijene nafte u USD po barelu, Brent Spot, deflator - indeks cijena pri proizvođačima SAD-a (prema Fred Economic data, 2018)
Izvor: Obrada autorice prema podacima DZS, 2017a (BDP); EIA, 2017 (cijena nafte)

[101] Lošiji je rezultat u EU ostvarila samo Grčka čiji se realni BDP u odnosu na 2008. godinu smanjio čak za četvrtinu.

Prvenstveno treba istaknuti relativno niske razine cijena u 90im godinama prošlog stoljeća gdje je rast cijena nafte uslijedio koncem 1990ih, što je bilo popraćeno promjenom načina definiranja (do tada administrativno određivanih) cijena naftnih derivata u skladu s cijenama na tzv. Mediteranskom tržištu. Od 2000. do 2008. godine, unatoč dugotrajnom stabilnom i izraženom trendu rasta cijena nafte, realna je ekonomija također rasla. Štoviše, kad se izračuna Pearsonov koeficijent korelacije između tih dvaju veličina (realnog BDP-a i cijena nafte), u periodu od 1995. do 2008., isti s iznosom od 0,936 pokazuje iznimno visoku pozitivnu korelaciju. No, već naočigled, mijenja se priroda odnosa u kriznom periodu, u kojem koeficijent korelacije iznosi -0,627. Kada se promotri cjelokupan period od 1995. do 2015. godine, koeficijent korelacije iznosi 0,827. Na prvi pogled podaci su u najmanju ruku zbunjujući, ipak treba imati na umu da sam koeficijent korelacije ne govori o utjecaju jedne varijable na drugu, već o tome u kojoj se mjeri (intenzitetu) i smjeru (predznak) poklapa njihovo kretanje. Smjer utjecaja jedne varijable na drugu, ako i postoji, pokazat će daljnja ekonometrijska analiza.

Konačno, unatoč skromnom doprinosu industrije BDP-u (oko 20% početkom, odnosno 15% koncem analiziranog perioda), nužno se osvrnuti na njihov međusobni odnos pogotovo kada se uzme u obzir da se upravo indeks industrijske proizvodnje na mjesečnoj razini često koristi kao procjenitelj (*engl. proxy*) kretanja ekonomske aktivnosti pa i BDP-a (što je slučaj i u ovom istraživanju).

Analiza međuodnosa BDP-a i industrijske proizvodnje ukazuje na njihovo iznimno blisko kretanje. Pearsonov koeficijent korelacije ovih je dvaju veličina u promatranom periodu (1995:Q1-2015:Q4) visokih 0,9657[102]. Važnost industrijskog sektora krije se u izraženim multiplikativnim efektima razvoja industrije na ostale sektore gospodarstva, pri čemu je važno istaknuti upravo prerađivačku industriju. Već je ranije istaknuta važnost izvoza u potenciranju realnog rasta (a ta je važnost posebno izražena kod zemalja koje poput RH imaju visoke razine vanjskog duga), a upravo je prerađivačka industrija glavni generator izvoznih aktivnosti u RH (a i uvoznih!) s gotovo 90% udjela u robnom izvozu (ali i 80% udjela u robnom uvozu, što govori o visokom stupnju intra-industrijske razmjene). Rafinerijska proizvodnja, odnosno izvoz

[102] Izračun autorice prema podacima: DZS, Industrija, Indeks industrijske proizvodnje (2018a) i DZS, Bruto domaći proizvod, tromjesečni obračun (2018b). Za period 1995Q1 do 1999Q4 tromjesečne vrijednosti BDP-a su aproksimirane Chow-Lin metodom temporalne dezagregacije jer DZS podatke o BDP-u na tromjesečnoj bazi objavljuje tek od 2000Q1.

derivata čini pri tome gotovo 10% vrijednosti robnog izvoza (*DZS, Priopćenje, robna razmjena Republike Hrvatske s inozemstvom u 2015*.).

Čavrak et al. (2006) su analizirali utjecaj cijena energenata (općenito) u svijetu i Hrvatskoj te njihov utjecaj na gospodarstvo u cijelosti. Autori konstatiraju kako bi povećanje cijena energije (svih vidova u prosjeku) smanjilo hrvatski BDP i povećalo cijene. Valja spomenuti i doktorsku disertaciju Tomislava *Gela* iz *2008*. godine u kojoj je autor ispitivao utjecaj svjetskih energetskih šokova na hrvatsko gospodarstvo, osvrćući se samo u pojedinim segmentima na cijene nafte. Autor zaključuje da realne cijene nafte ne utječu negativno na kretanje BDP-a, što je u potpunoj suprotnosti s postojećim teorijskim spoznajama te predstavlja dodatnu motivaciju za provjeru spomenute tvrdnje alternativnim metodama.

Na ovom je mjestu vrijedno spomenuti i istraživanje *Jovičića i Kunovca (2017*) koji, na tragu istraživanja *Krznara i Kunovca (2010) i Globan et al. (2015)* o značajnom doprinosu inozemnih šokova realnim kretanjima hrvatskog BDP-a, u istraživanje uključuju i aspekt šokova svjetskih cijena nafte. Istražujući, strukturnim VAR modelom, doprinos domaćih i inozemnih šokova kretanju hrvatskog BDP-a (2001:Q1-2016:Q2), *Jovičić i Kunovac (2017),* temeljem dekompozicije varijance realnog BDP-a konstatiraju da inozemni šokovi (svjetski i šokovi euro zone) imaju visok utjecaj na varijabilnost BDP-a od oko 40%. Također ističu puno veći utjecaj domaćih šokova na strani ponude na varijacije u BDP-u u odnosu na domaće šokove na strani potražnje. Nadalje, navode da je pad cijena nafte (Brent cijena nafte u USD) koncem analiziranog perioda prvenstveno posljedica slabe globalne potražnje, a manje povoljnih uvjeta na strani ponude nafte pri čemu koeficijent koji procjenjuje utjecaj cijena nafte na BDP ima promjenjiv predznak tokom analiziranog perioda, i to mahom pozitivan (Grafikon 3.1.5.).

Grafikon 3.1.5.: Procjena utjecaja cijena nafte na realni BDP, vremenska dekompozicija za period (2002.-2016.), medijan +/- 1 S.D. (68% interval pouzdanosti), godišnje stope rasta

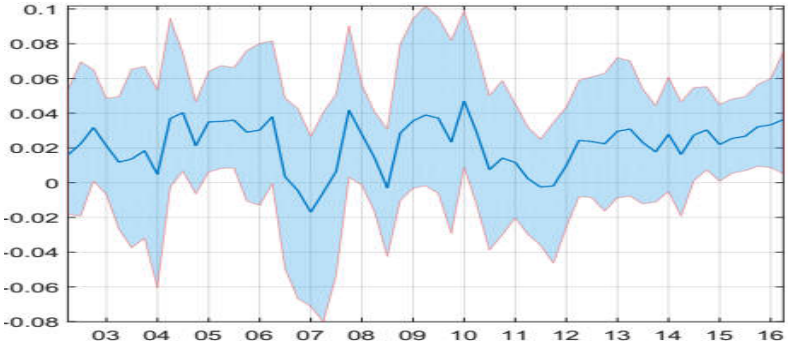

Izvor: *Jovičić i Kunovac (2017),* str.15.

Ovakav zaključak je oprečan teorijski očekivanom rastu BDP-a uslijed pada cijena nafte. Ipak, ako je pad cijena nafte produkt primarno slabe globalne potražnje, korist nižih cijena nafte ne može adekvatno kompenzirati globalni pad potražnje. Kao moguće pojašnjenje ove pojave mogli bi poslužiti rezultati *Šušnjara (2014)* koji je istraživanjem cjenovne i dohodovne elastičnosti potražnje za naftnim derivatima u RH (u periodu od siječnja 2006. do prosinca 2010.) zaključio da je dohodovna elastičnost potražnje veća od cjenovne elastičnosti potražnje za naftnim derivatima (motornim benzinom i dizelom) odnosno da je potražnja za naftnim derivatima prvenstveno funkcija dohotka, a tek onda njihovih cijena.

Važno je naznačiti i konstataciju *Jovičić i Kunovac (2017)* koji, iako fokusirani na naftne šokove na strani ponude, evidentiraju značaj globalne potražnje u kretanju istih od 2002. godine naovamo. O istome svjedoči i Grafikon 3.1.6. na kojem je evidentno da se većina kretanja svjetskih cijena nafte (crna linija) može pripisati upravo globalnoj realnoj aktivnosti (modri stupci), a tek u manjoj mjeri kretanjima na strani ponude nafte (sivi stupci).

Grafikon 3.1.6.: Povijesna dekompozicija cijena nafte s komponentama koje su doprinijele njihovim promjenama, godišnje stope rasta

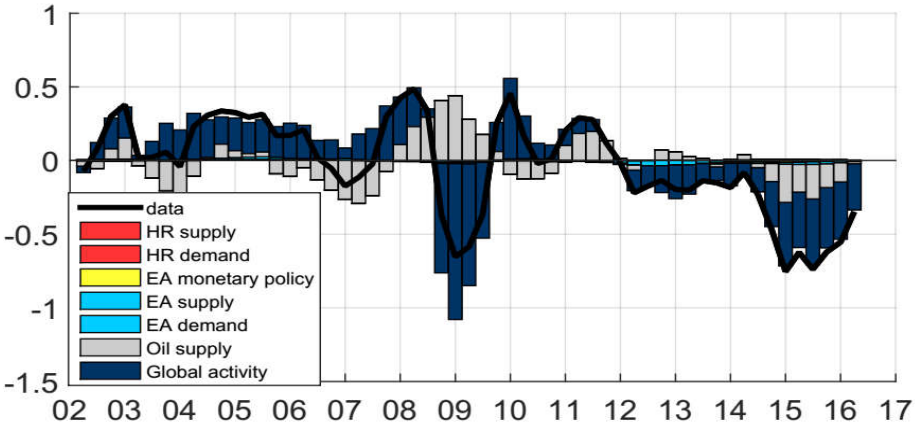

Izvor: *Jovičić i Kunovac (2017),* str.15.

S druge pak strane *Narayan et al. (2014)* tvrde da je temeljem cijena nafte moguće pouzdanije predviđati buduće stope realnog rasta, između ostalih zemalja i u RH (1998:Q2-2011:Q2), kao i da je utjecaj cijena nafte na gospodarski rast negativan i statistički značajan. Nadalje, procjenjujući učinak naftnih šokova kao i šokova monetarne politike euro zone na poslovne cikluse CEE zemalja izvan euro zone, uključujući i Hrvatsku (1999:Q1-2015:Q4), *Cavallo i Ribba (2017)* zaključuju da rast cijena nafte pozitivno utječe na cijene zemalja iz uzorka te, istovremeno, negativno na njihove realne outpute (s izuzetkom Litve). Tako navode da rast cijena nafte od 10% rezultira padom hrvatskog BDP-a za 0,95% (nakon 12 tromjesečja).

Nadalje, autori navode da varijabilnost nacionalnog outputa u kratkom roku ponajviše pojašnjavaju interni strukturni šokovi dok u dugom roku, kod svih analiziranih gospodarstva, naftni šokovi pojašnjavaju najveći dio varijabilnosti nacionalnog outputa.

Analiza kretanja BDP-a u cijelom razdoblju nakon Domovinskog rata pokazuje da je ostvareni rast prije svega omogućen niskom bazom realnog BDP-a, ali i znatno potpomognut snažnom kreditnom aktivnošću i vanjskim zaduživanjem. Realni BDP je u periodu od 1995. do 2015. povećan za gotovo 50% (na godišnjoj razini), s prosječnom godišnjom stopom rasta od skromnih 2,24%, pri čemu (dugoročno) kretanje BDP-a upućuje na potrebu daljnjih (značajnijih) pomaka u ekonomskoj politici. Koja je uloga cijena nafte u kretanju BDP-a, postojeće analize istog ne otkrivaju nedvojbeno. Štoviše, postojeća istraživanja, iako u mnogočemu manjkava, upućuju na pozitivan utjecaj cijena nafte na realni rast u RH, oprečan onom teorijski očekivanom.

3.2. INFLACIJA KAO MAKROEKONOMSKI POKAZATELJ

Svaka ekonomija teži održivom gospodarskom rastu kojem je stabilnost cijena osnovni preduvjet. Upravo zato, stabilnost cijena, točnije niska i stabilna inflacija, predstavlja ključni cilj središnjih banaka. U skladu s navedenim, slijedom prakse Europske središnje banke, a prema čl. 3. Zakona o Hrvatskoj narodnoj banci (*NN 75/08, 54/13*), primarni proklamirani cilj HNB-a jest održavanje stabilnosti cijena, pri čemu razina inflacije kojoj teži HNB nije eksplicitno određena.

Okvir monetarne politike HNB-a temelji se na održavanju stabilnosti nominalnog tečaja kune prema euru. Stabilan tečaj kune prema euru predstavlja tzv. nominalno sidro monetarne politike kojim HNB stabilizira inflacijska očekivanja, a naposljetku i inflaciju (*HNB, 2018b*). Održavanjem stabilnosti tečaja kune prema euru HNB posredno utječe na svoj temeljni cilj, a s obzirom na visoku euroizaciju hrvatskoga bankovnog sustava, stabilnost tečaja je alat kojim HNB održava i financijsku stabilnost. Izbor monetarnog okvira i sidra monetarne politike ovisi o važnim obilježjima i osobitostima gospodarstva, a za hrvatsko gospodarstvo to su (*HNB, Okvir monetarne politike, 2018; HNB, 2018b*):

⇒ izrazito visoka razina euroizacije (visoka stupanj depozitne i kreditne euroizacije[103] i mjerila vrijednosti),

⇒ činjenica da je Hrvatska malo i otvoreno gospodarstvo, pri čemu se više od polovine robnog izvoza i oko 60% robnog uvoza odnosi na zemlje članice euro zone[104],

⇒ visoka uvozna ovisnost[105] te

⇒ visoka zaduženost u stranoj valuti svih domaćih sektora.

Domaći novac (kuna) više služi kao sredstvo razmjene, a strani novac (primarno euro) kao čuvar vrijednosti. Štoviše, istraživanja *Luca i Petrova (2008)* i *Levy Yeyati (2006)* ističu upravo Hrvatsko[106] gospodarstvo kao ono s najvišim stupnjem euroizacije u Europi.

Slijedi prikaz i analiza kretanja inflacije u Hrvatskoj od 1995. do 2015. godine uz pomoć indeksa potrošačkih cijena (CPI – *engl. Consumer Price Index*)[107]. Na Grafikonu 3.2.1. prikazane su mjesečne stope inflacije u RH.

Grafikon 3.2.1.: Mjesečne stope inflacije (plava linija) i bazni indeks potrošačkih cijena (2010=100)*

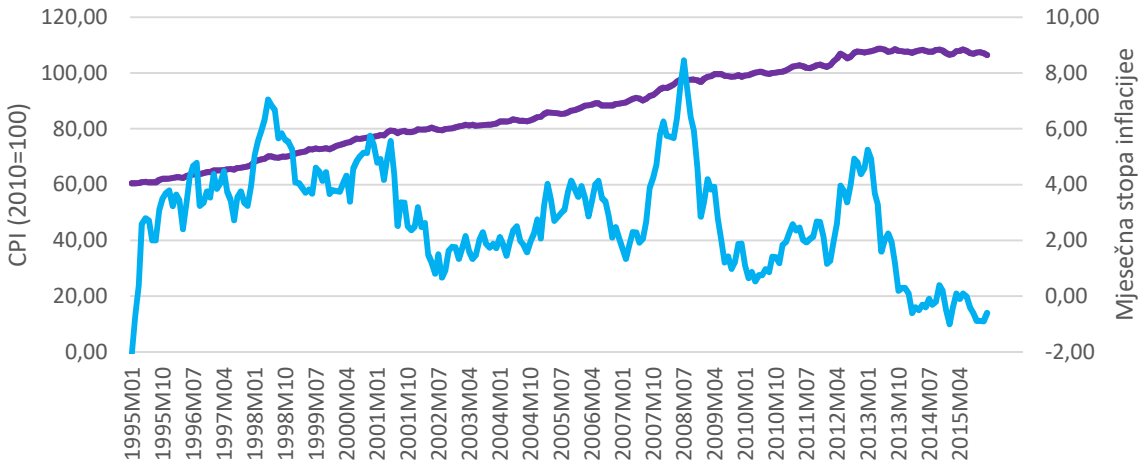

*CPI za period 1995M01-1997M12 aproksimiran je uz pomoć pokazatelja cijena na malo, prema DZS, Cijene i troškovi života u 1998 (1999)
Izvor: Izračun autorice prema podacima HNB, Indeksi potrošačkih cijena i proizvođačkih cijena industrije (2018)

[103] Oko dvije trećine plasmana hrvatskih banaka vezano je uz tečaj strane valute (uglavnom tečaj eura).
[104] Veća kolebanja tečaja kune prema euru dovela bi do učestalije promjenjivosti uvoznih i izvoznih cijena, čime bi se otežala njihova predvidivost i povećala neizvjesnost u poslovanju s inozemstvom.
[105] Velik dio dobara na hrvatskom tržištu potječe od uvoza iz euro područja stoga bi znatniji porast tečaja kune prema euru mogao bi dovesti do rasta cijena tih dobara izraženih u kunama, a posredno i do rasta inflacije.
[106] pored Armenije i Gruzije
[107] Kako su podaci za CPI dostupni tek od siječnja 1998., CPI za period 1995M01-1997M12 aproksimiran je uz pomoć pokazatelja cijena na malo, prema DZS, Cijene i troškovi života u 1998 (1999)

Potrošačke su cijene, prikazane baznim indeksima potrošačkih cijena, kroz promatrani period (1995:M01-2015:M12) rasle sve do 2012. kada započinje njihova stagnacija, a potom i blagi pad (deflacija). Opća je razina cijena u navedenom periodu povećana za 73,6%, a u istom je periodu hrvatski BDP realno porastao za 55,38%, što upućuje na zaključak da su cijene rasle brže od realne ekonomije. Prosječna mjesečna stopa inflacije iznosila je 2,83%, pri čemu je standardna devijacija iznosila svega 1,87. Ovi podaci svjedoče o iznimno stabilnoj inflaciji u Hrvatskoj u promatranom periodu. Skokovi, odnosno značajnija odstupanja inflacije u odnosu na njenu prosječnu vrijednost vidljivi su u nekoliko perioda (pozitivna odstupanja: 1998., 2001., 2007./2008. i 2012./2013. i negativna: koncem analiziranog perioda; 2014. i 2015.). HNB u svojim periodičkim publikacijama (*HNB, Godišnje izvješće*, razna godišta) nudi detaljne opise kretanja inflacije kao i pojašnjenja uzroka (pozitivnih i negativnih) promjena iste.

Na viši rast cijena i troškova života tijekom 1998. najviše je utjecalo uvođenje poreza na dodanu vrijednost (PDV) početkom godine. Ipak, utjecaj uvođenja PDV-a na cijene bio je isključivo jednokratnog karaktera (*HNB, Godišnje izvješće, 1998*).

Rastu inflacije koncem 2000. (i početkom 2001.) pridonijeli su znatna deprecijacija kune prema američkom dolaru i poskupljenje sirove nafte na svjetskom tržištu koje se odrazilo na gotovo 40%-tni rast cijena naftnih derivata na domaćem tržištu (u odnosu na prethodnu godinu). Osim toga, povećane su i trošarine i administrativno regulirane cijene (*Kraft, 2003*). Pod utjecajem pojeftinjenja sirove nafte na svjetskom tržištu, ali i zahvaljujući stabilizaciji deviznog tečaja i povećanju konkurencije u sektoru trgovine (ulaskom nekolicine novih trgovačkih lanaca na tržište), u drugoj polovini 2001. dolazi do smanjenja inflatornih pritisaka (*HNB, Godišnje izvješće, 2001*).

U drugoj polovini 2007. godine došlo je do znatnog ubrzanja inflacije na što su najviše utjecali poskupljenje prehrambenih proizvoda i naftnih derivata (*Bebek i Santini, 2008*), odnosno povećanje cijena sirove nafte na svjetskom tržištu *(HNB, Godišnje izvješće, 2007)*. Među domaćim činiteljima koji su potaknuli rast inflacije može se izdvojiti znatan rast agregatne potražnje u 2007. godini, osobito osobne potrošnje (*Sorić, 2012*), čiji se odgođeni učinak na inflaciju osjetio i tijekom prve polovine 2008. Na zamjetno usporavanje inflacije potrošačkih

cijena u drugom dijelu 2008. najviše je utjecalo usporavanje rasta osobne potrošnje, ali i smanjenje uvezenih inflatornih pritisaka (*HNB, Godišnje izvješće, 2008*)[108].

Sljedeći skok cijena uslijedio je, u sada već periodu duboke krize u Hrvatskoj, na prijelazu 2012. na 2013., pri čemu je ubrzavanje inflacije u 2012. ponajviše bilo posljedica administrativnih odluka[109]. Pritom je na kretanje uvoznih cijena nepovoljno djelovalo i slabljenje kune prema američkom dolaru. Koncem godine dolazi do slabljenja inflacijskih pritisaka jer u posljednja dva mjeseca 2012. dolazi do pada cijena sirove nafte. Godišnja stopa inflacije znatno se smanjila tijekom 2013. pri čemu se najviše smanjio doprinos cijena energije i prehrambenih proizvoda. Ovome svakako valja dodati i iznimno slabu domaću potražnju (*HNB, Godišnje izvješće, 2013).*

Konačno, drastično smanjena inflacija do konca 2013. nastavila je značajan pad i u 2014. u kojoj je fluktuirala oko nulte stope, da bi u 2015. prešla u deflaciju. Pad prosječnih godišnjih stopa inflacije potrošačkih cijena ponajviše je bio posljedica prelijevanja nižih cijena sirove nafte na domaće cijene, ali i pada cijena prehrambenih sirovina na svjetskom tržištu, te u manjoj mjeri, niske temeljne inflacije u euro zoni, smanjenja administrativnih cijena (osobito cijene prirodnog plina[110]) i odsutnosti domaćih inflatornih pritisaka s potražne i troškovne strane *(HNB, Godišnje izvješće, 2015).*

Osim istaknute analize kretanja inflacije u proteklih 25 godina, važno je usporediti i inflaciju u Hrvatskoj u odnosu na EU, odnosno njene članice usporedivih gospodarskih karakteristika. Usporedba kretanja harmoniziranog indeksa potrošačkih cijena (HICP – *engl. Harmonised Indices of Consumer Prices*) u Hrvatskoj, euro zoni i EU10 u periodu od 1999. do 2015. godine (prema podacima *Eurostat, HICP, 2018*) ukazuje na blisko kretanje inflacije u Hrvatskoj u odnosu na euro zonu, iako su stope inflacije u Hrvatskoj ipak nešto više. Na tragu iznijetog, standardna devijacija HICP (kao pokazatelj volatilnosti inflacije) za euro zonu iznosila je 0,87, za Hrvatsku 1,46, a za EU10 prosječno 2,79 postotnih poena. Navedeno implicira da je volatilnost inflacije izraženija u EU10 članicama u odnosu na Hrvatsku, odnosno u Hrvatskoj

[108] Pad cijena nafte, prehrambenih sirovina i metala na svjetskom tržištu kao odraz usporavanja globalnoga gospodarskog rasta.
[109] Rast opće stope PDV-a s 22% na 25% u ožujku, kao i poskupljenja električne energije i plina u svibnju. Administrativnim odlukama povećane su i cijene vode, javnog prijevoza i zagrijavanja stana (*HNB, Godišnje izvješće, 2012*).
[110] Cijene plina su pale kao „odgovor“ na smanjenje cijena sirove nafte.

u odnosu na euro zonu. Blisko kretanje inflacije u Hrvatskoj i euro zoni i nije toliko čudno ako se uzme u obzir da je upravo tečaj HRK/EUR nominalno sidro u vođenju monetarne politike i temeljno sredstvo za postizanje cilja niske i stabilne razine inflacije. S druge strane, prosječna razina inflacije u grupaciji post-tranzicijskih zemalja EU10 je ipak viša u odnosu na RH pa se može zaključiti da je, po pitanju kretanja cijena, Hrvatska među najučinkovitijim post-tranzicijskim zemljama (*Bebek i Santini, 2008*). Na istom tragu, *Botrić i Cota (2006)* smatraju da dokazivanje različitosti u procesu generiranja inflacije među post-tranzicijskim ekonomijama implicira važnost pojedinačnog sagledavanja pojedinog gospodarstva uvažavajući njegove specifičnosti.

Grafikonom 3.2.2. prikazane su godišnje stope inflacije s doprinosom pojedinih komponenti inflaciji potrošačkih cijena (prema kalkulacijama HNB-a). Crnom je bojom naznačen doprinos cijena energije promjenama potrošačkih cijena i jasno je vidljiv značajan doprinos njihovih promjena ukupnom kretanju potrošačkih cijena.

Grafikon 3.2.2.: Godišnje stope inflacije i doprinosi komponenata inflaciji potrošačkih cijena u Hrvatskoj (2006M01-2015M12)

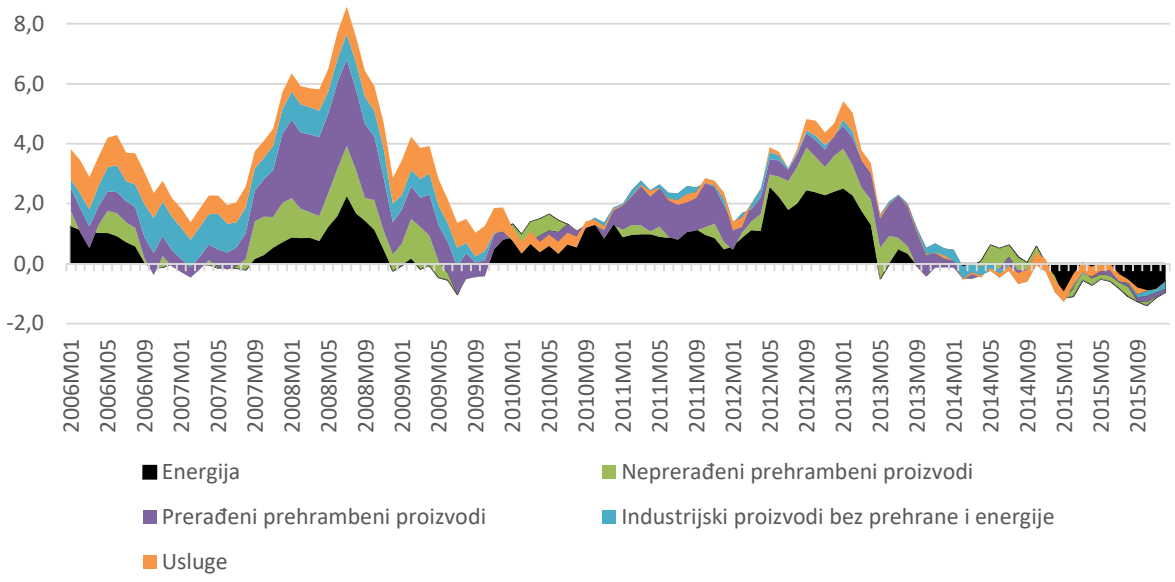

Izvor: HNB, Godišnje stope inflacije i doprinosi komponenata inflaciji potrošačkih cijena u Hrvatskoj (2018)

Kako doprinos cijena energije ne podrazumijeva samo doprinos cijena nafte (naftnih derivata), važno je zasebno promotriti i usporedno kretanje inflacije i cijena nafte (iako je o utjecaju cijena nafte već i bilo riječi kroz analizu inflacije potrošačkih cijena) prikazano Grafikonom 3.2.3. Cijene nafte izražene su u kunama kako bi se izolirao utjecaj promjene tečaja kune u odnosu na američki dolar. Promatrajući prvi dio perioda (do 2000. godine), ne nazire se očita veza cijena

nafte i inflacije. Već samim početkom novog milenija rast cijena nafte koincidira s rastom inflacije, a gotovo okom vidljivo usporedno kretanje cijena nafte i inflacije (u periodu od 2000. do 2008.) potvrđuje i relativno visok Pearsonov koeficijent korelacije cijena nafte (kn/barel) i CPI-a (2010=100) od 0,65. U narednom periodu, od 2009. nadalje, veza naočigled slabi, iako je u pojedinim godinama doprinos cijena nafte inflaciji (a kasnije i deflaciji) ipak bio značajan.

Grafikon 3.2.3.: Kretanje mjesečnih stopa inflacije i nominalnih cijena nafte u kunama po barelu* (1995M01-2015M12)

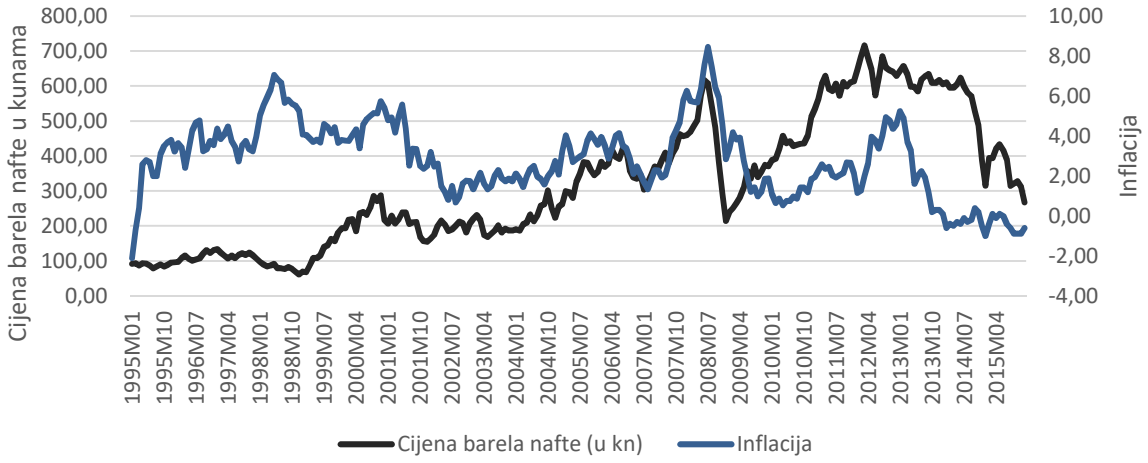

*Nominalne cijene nafte u kunama izračunate su umnoškom nominalne cijene nafte (Brent Spot, u USD) i srednjeg tečaja USD (prema HNB, Srednji tečaj HNB-a, 2018)
Izvor: Izračun autorice prema podacima HNB, Indeksi potrošačkih cijena i proizvođačkih cijena industrije (2018) i EIA, Europe Brent Spot Price FOB (2017)

I *Krtalić i Benazić (2008)* ističu da je za snažan porast cijena i jačanje inflacije početkom trećeg milenija ponajviše „kriv“ upravo rast cijena nafte na svjetskom tržištu. Rast cijena nafte sa sobom je povukao i cjelokupan rast cijena energenata, prehrambenih proizvoda i prijevoza te je stoga postao glavni problem ekonomskih politika gotovo svih zemalja u svijetu pa tako i Hrvatske. U nešto ranijem istraživanju *Kraft (2003)* smatra (1995:M01-2002:M03) kako u Hrvatskoj cijene nafte Granger uzrokuju PPI[111] (kroz 12 mjeseci), ali ne i CPI, pri čemu PPI utječe na CPI, ali s vremenskim odmakom od 7 odnosno 12 mjeseci. Shodno navedenom, *Kraft (2003)* zaključuje da naftni šokovi nemaju značajan utjecaj na CPI, već je PPI pod snažnim utjecajem svjetskih cijena pri čemu se ipak, nešto sporije, promjene u PPI-u prelijevaju i u promjene CPI-a. *Malešević Perović (2009)* također navodi da su cijene nafte utjecale na rast inflacije nakon 2001. godine kada su cijene naftnih derivata počele u većoj mjeri odražavati

[111] Indeks cijena pri proizvođačima – **PPI** (**P**roducer **P**rice **I**ndex)

kretanje svjetskih cijena nafte. Iste godine, analizirajući[112] izvore inflacije unutar grupacije europskih gospodarstava u razvoju[113], uključujući i Hrvatsku, *Zoli (2009)* zaključuje da je reakcija inflacije od 0,1 postotnog poena na 10% rasta cijena nafte (nakon 6 mjeseci) najskromnija upravo u Hrvatskoj (u odnosu na 1,3 postotna poena što čini prosječnu reakciju unutar analizirane grupacije zemalja).

Istražujući učinke prelijevanja vanjskih šokova na inflaciju u Hrvatskoj (2000:Q2-2010:Q1), *Krznar i Kunovac (2010)* zaključuju da su upravo inozemni činitelji glavne determinante domaće inflacije. Na tragu navedenog, zanimljivo istraživanje proveli su i *Globan et al. (2014)* istražujući doprinos domaće i inozemne komponente (šokova) inflaciji u novim članicama EU-a koje nisu članice euro zone[114] (2001:M05-2013:M06). Za razliku od svih ostalih analiziranih ekonomija, jedino je u Hrvatskoj i u kratkom i srednjem roku[115] izraženija inozemna komponenta inflacije u doprinosu ukupnoj inflaciji, pri čemu se kod svih zemalja korelacija inozemne komponente u odnosu na inflaciju smanjila u vrijeme krize (2009-2011)[116].

Također, *Jovičić i Kunovac (2017)* konstatiraju da inozemni (svjetski i europski) šokovi imaju visok utjecaj na varijabilnost inflacije u Hrvatskoj, od oko 50% (2001:Q1 – 2016:Q2). Autori navode i da je pad cijena nafte značajno doprinio padu inflacije koncem analiziranog perioda. Pri tome isti ističu da je ovaj odnos ovisan i o samom inicijalnom uzroku naftnog šoka (da li je isti posljedica poremećaja na strani ponude ili potražnje za naftom). Tako konstatiraju da je pad cijena nafte koncem analiziranog perioda prvenstveno posljedica slabe globalne potražnje, a manje povoljnih uvjeta na strani ponude nafte. Procjenjujući utjecaj šokova na inflaciju, *Jovičić i Kunovac (2017)* zaključuju da je koeficijent kojim procjenjuju utjecaj cijena nafte na domaću inflaciju, iako varijabilan, pozitivan.

Slijedom iznesenog, pitanje efikasnosti monetarne politike kontinuirano privlači pažnju akademskih krugova jer je upravo poznavanje odnosa monetarnih i realnih varijabli nužan

[112] U periodu od 1990ih do 2008 (uzorak se blago razlikuje među zemljama).
[113] Bugarska, Hrvatska, Češka, Estonija, Mađarska, Litva, Latvija, Srbija, Slovačka, Slovenija, Turska i Ukrajina.
[114] Bugarska, Češka, Hrvatska, Latvija, Litva, Mađarska, Poljska i Rumunjska
[115] U srednjem roku i kod preostalih analiziranih zemalja dolazi do povećanja udjela inozemne komponente u doprinosu inflaciji (u odnosu na domaću komponentu).
[116] Autori smatraju da je navedeno posljedica strelovitog pada uvoza, koji je uslijedio uslijed krize, što je ograničilo inozemni utjecaj na domaću inflaciju u promatranom periodu.

preduvjet maksimizacije efekata koji pridonose rastu cjelokupnog gospodarstva, a time i životnog standarda građana (*Doležal, 2011*). Iako su rezultati istraživanja o efikasnosti transmisijskih mehanizama monetarne politike[117] u Hrvatskoj nerijetko oprečni, općenito se može izvući prevladavajući stav znanstvenika da je kanal deviznog tečaja najefikasniji transmisijski mehanizam (cf.: *Payne, 2002; Kraft, 2003; Botrić i Cota, 2006; Vizek, 2006; Vizek i Broz, 2007; Malešević-Perović, 2009; Benazić, 2009; Borozan, 2011; Doležal, 2011; Borozan i Sonora, 2014*), što i ne čudi s obzirom na prethodno iznijet odabrani okvir provođenja monetarne politike od strane HNB-a (temeljen na specifičnostima hrvatskog gospodarstva).

Kao podloga za predloženo istraživanje u ovoj disertaciji, u nastavku slijedi analiza kretanja deviznog tečaja, novčane mase i kamatne stope s ciljem analize njihovog utjecaja na inflaciju.

Grafikonom 3.2.4. prikazano je kretanje indeksa realnog (*engl. Real Effective Exchange Rate – REER*) i nominalnog efektivnog deviznog tečaja (*engl. Nominal Effective Exchange Rate – NEER*)[118].

Kretanje REER u promatranom dvadesetogodišnjem periodu pokazuje relativno skromne oscilacije, posebice kada se promatra NEER. Ipak, krenuvši od 2000. godine evidentan je trend, kako realne tako i nominalne, efektivne aprecijacije tečaja sve do početka krize koncem 2008. Nakon oscilacija u periodu od kraja 2008. do kraja 2009., uočava se trend realne/nominalne deprecijacije tečaja sve do kraja promatranog razdoblja kada REER (a i NEER) doseže razinu iz 2001. godine[119].

---

[117] Pojam transmisijskog mehanizma monetarne politike označava proces preko kojega se odluke monetarne vlasti prelijevaju na realne varijable u gospodarstvu (*Ivanov i Čavrak, 2005*). Što su učinci prelijevanja jači to znači i da je pojedini transmisijski mehanizam (npr. kamatne stope, deviznog tečaja, novčane mase) efikasniji. Ako je financijska struktura razvijena, prijenos impulsa monetarne politike na financijske i realne transakcije je brži i efikasniji, dok je u zemljama sa slabo razvijenim financijskim tržištem njihov prijenos slab, a u pojedinim segmentima može biti i potpuno blokiran (*Perišin et al., 2001*).

[118] Indeks nominalnoga efektivnog tečaja kune ponderirani je geometrijski prosjek indeksa bilateralnih nominalnih tečajeva kune prema odabranim valutama glavnih trgovinskih partnera i predstavlja agregatni pokazatelj prosječne vrijednosti domaće valute prema košarici stranih valuta. Indeks realnoga efektivnog tečaja ponderirani je geometrijski prosjek indeksa bilateralnih tečajeva kune korigiranih indeksom potrošačkih cijena (odnos potrošačkih cijena u zemljama partnerima i domaćih cijena).

[119] Ovi se aprecijacijski pritisci mogu dovesti u vezu sa snažnim priljevom inozemnog kapitala, kao i izostankom istog u periodu krize obilježenom deprecijacijom (*Bukovšak et al., 2017*). Među ključnim negativnim utjecajima priljeva kapitala na gospodarstvo zemlje primateljice ističe se gubitak konkurentnosti zbog aprecijacije realnog tečaja (*Calvo et al., 1993; Corden, 1994; Lartey, 2008*). Razina deviznog tečaja je stoga, izuzev istaknute važnosti vezane za inflacijska očekivanja (pa posredno i inflaciju), iznimno važna u kontekstu konkurentnosti hrvatskog gospodarstva u međunarodnim okvirima.

Grafikon 3.2.4.: Indeksi kretanja realnog i nominalnog efektivnog deviznog tečaja, 2010=100*

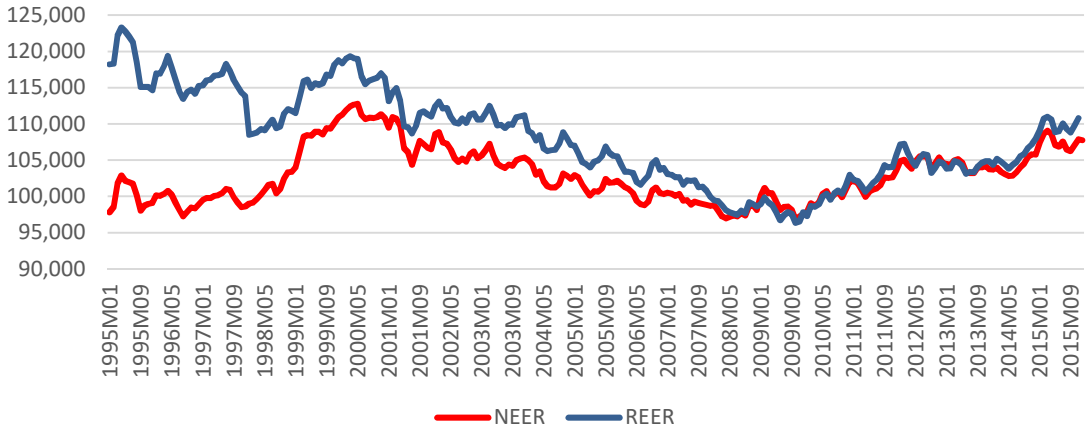

*Pad indeksa označava realnu efektivnu aprecijaciju.
Izvor: HNB, Indeksi efektivnih tečajeva kune (2018)

Upravo se tečaj američkog dolara najtješnje vezuje uz kretanje cijena nafte na svjetskom tržištu jer je riječ o robi čija se cijena određuje upravo u američkim dolarima. Iako se ovo odnosi na tečaj dolara na svjetskoj razini, ove se promjene neminovno pretaču i na bilateralni tečaj HRK/USD. Grafikonom 3.2.5. prikazani su prosječni mjesečni bilateralni devizni tečajevi EUR/HRK i USD/HRK kao i prosječna mjesečna cijene nafte u USD po barelu. Prvenstveno je očigledna znatna varijabilnost bilateralnog tečaja HRK/USD u odnosu na stabilan tečaj HRK/EUR.

Grafikon 3.2.5.: Prosječni mjesečni bilateralni devizni tečajevi EUR/HRK i USD/HRK i prosječna mjesečna cijene nafte u USD po barelu

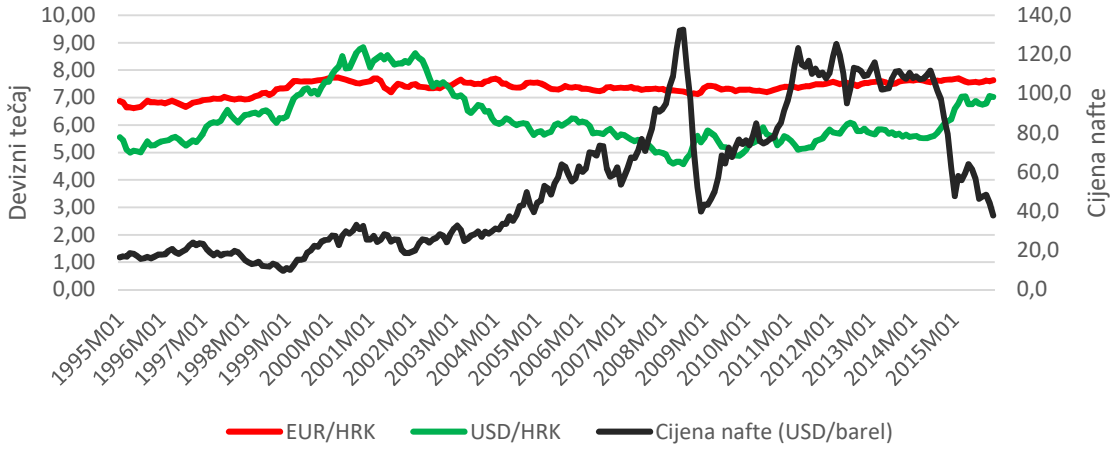

Izvor: Obrada autorice prema podacima HNB, Srednji tečaj HNB-a (2018), i EIA, Europe Brent Spot Price FOB (2017)

Periode deprecijacije dolara uglavnom prati rast cijena nafte. Vrijedi i obratno. Tako je paralelno s deprecijacijom dolara vidljiv i rast nominalnih cijena nafte od rekordnih 132 USD

u srpnju 2008. kada, istovremeno, i američki dolar doseže najnižu vrijednost u promatranom periodu, tečaj 1 USD = 4,58 HRK. Od polovine 2014. (s razina od iznad 100 USD po barelu) kreće kontinuirani pad cijena nafte (na vrijednost od svega 30ak USD po barelu koncem 2015.) popraćen izrazitom aprecijacijom američkog dolara čija je nominalna vrijednost od kolovoza 2014. do prosinca 2015. porasla za čak 27,4% (sa 1 USD = 5,52 HRK na 1 USD = 7,03 HRK).

Pitanje razine deviznog tečaja (posebno bilateralnog tečaja EUR/HRK) među važnijim je makroekonomskim pitanjima kod malog otvorenog, a istovremenog iznimno zaduženog, gospodarstva poput Hrvatskog. Iako su učinci aprecijacije kune na smanjenje tereta duga privatnog i javnog sektora denominiranog u stranoj valuti, kao i na pozitivne šokove agregatne ponude i nižu stopu inflacije (zbog učinaka na nižu cijenu uvoza), pozitivni, druga strana priče je istovremeni negativan utjecaj na konkurentnost (vrijedi i obratno, u situaciji deprecijacije).

Grafikon 3.2.6. prikazuje kretanje i stope rasta monetarnog agregata M1 od siječnja 1995. do prosinca 2015. Crvena linija koja prikazuje mjesečne postotne promjene novčane mase ukazuje na relativno stabilne oscilacije uglavnom u granicama ±5%, odnosno ±15% kad se uvaže ekstremne vrijednosti.

Grafikon 3.2.6.: Kretanje novčane mase (M1), u milijunima HRK, i mjesečne stope rasta

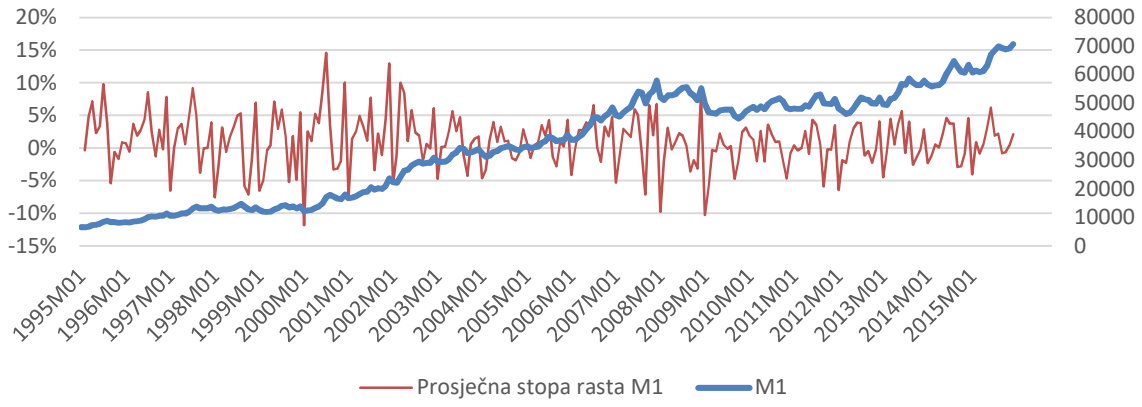

Izvor: Obrada autorice prema podacima HNB, Monetarni i kreditni agregati (2018)

Prema podacima na grafikonu, evidentan je umjeren rast novčane mase koncem 1990ih, koji s početkom 2000. godine prelazi u intenzivan rast okončan tek 2008. godine, s prvim naznakama krize. Kako navode *Bokan et al. (2010),* od sredine 2008. odobravanje kredita stanovništvu gotovo je zaustavljeno, a rast ukupnih kredita privatnom sektoru dodatno usporen. U periodu krize novčana je masa kontinuirano oscilirala uz istaknuto smanjenje od više od 20% do konca 2009. godine. Najviša predkrizna razina novčane mase iz prosinca 2007. godine dosegnuta je

ponovno tek u kolovozu 2013. Iste godine započinje i ponovni izražen rast novčane mase sve do konca promatranog razdoblja.

Upravo je politika sidra nominalnog deviznog tečaja uzrok tijesne veze novčane mase i deviznih pričuva. Navedena je veza evidentna pogledom na, Grafikonom 3.2.7. prikazane, podatke o međunarodnim deviznim pričuvama i novčanoj masi. Ublažavanje aprecijacijskih pritiska središnja banka uglavnom vrši otkupom deviza, a kupovina deviza u pravilu znači emitiranje kuna. Kako je model razvoja uglavnom baziran na uvozu inozemne štednje, vidljiv je gotovo kontinuiran rast deviznih pričuva (s iznimkom kriznih godina kada je i smanjen priljev inozemne štednje), a usporedno i novčane mase.

Grafikon 3.2.7.: Međunarodne devizne pričuve i novčana masa

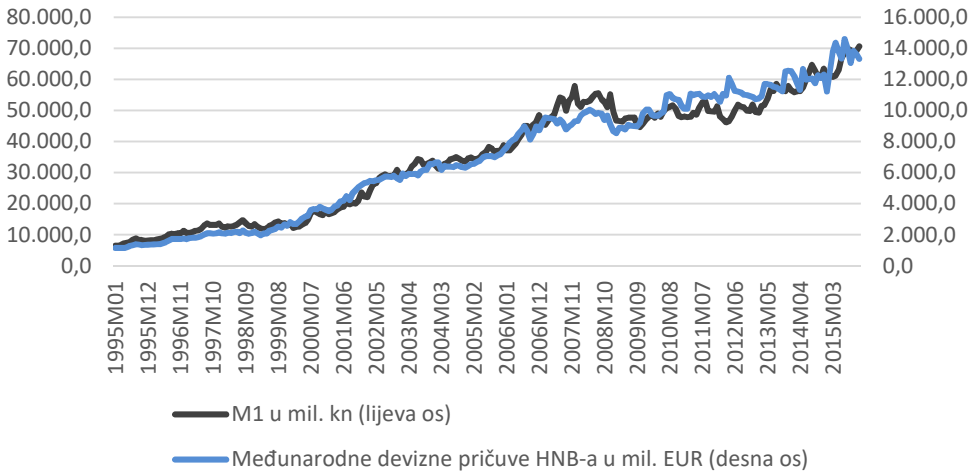

Izvor: Obrada autorice prema podacima HNB, Monetarni i kreditni agregati (2018) i HNB, Međunarodne pričuve HNB-a i devizne pričuve banaka (2018)

Pojedina istraživanja upućuju na značajan učinak rasta realne novčane mase na gospodarsku aktivnost (*cf. Vizek, 2006; Vizek i Broz, 2007*[120]*; Doležal, 2011*). Ipak, reakcije gospodarske aktivnosti na promjene novčane mase uglavnom su relativno skromne. S druge strane, i o utjecaju novčane mase na inflaciju u RH i dalje je teško donositi definitivne i jednoznačne odgovore jer postojeća istraživanja[121] nude oprečne zaključke (*Obadić i Tica, 2016, str. 263.*).

[120] Zaključuju kako rast novčane mase (M1) od 1% dovodi do rasta razine cijena za 0,07% (i do rasta industrijske proizvodnje za 0,146% u dugom roku).
[121] *Erjavec et al. (1999), Vizek i Broz (2007), Borozan (2011), Doležal (2011)*

Izgradnja kamatnog transmisijskog mehanizma kroz institucionalne reforme je od velike važnosti u kontekstu uvođenja eura jer je kamatna stopa i jedini instrument monetarne politike unutar Eurolanda *(Vizek, 2006).*

Početkom 2002. predstavljena je jedinstvena referentna kamatna stopa za hrvatsku kunu na hrvatskom međubankarskom tržištu – ZIBOR (Zagreb InterBank Offered Rate). Unatoč tome, istraživanje banaka iz 2008. godine (*Ivičić et al., 2008*) pokazuje kako bankarski sektor ne smatra ZIBOR referentnom kamatnom stopom. Naprotiv, kao najznačajniju kunsku referentnu kamatnu stopu hrvatske banke navode onu realiziranu u međubankovnoj trgovini (dok za plasmane u eurima kao referentne stope koriste LIBOR i EURIBOR). Podaci na Grafikonu 3.2.8., koji prikazuju usporedno kretanje ZIBOR i prosječne mjesečne kamatne stope na Tržištu novca Zagreb, ukazuju na njihovo iznimno blisko kretanje. Koeficijent korelacije njihova kretanja u periodu 2002:M09-2015:M12 iznosi visokih 0,968, zbog čega je i u empirijskom dijelu disertacije ista korištena kao referentna kamatna stopa.

Grafikon 3.2.8.: ZIBOR i prosječne mjesečne kamatne stope (IR) na Tržištu novca Zagreb

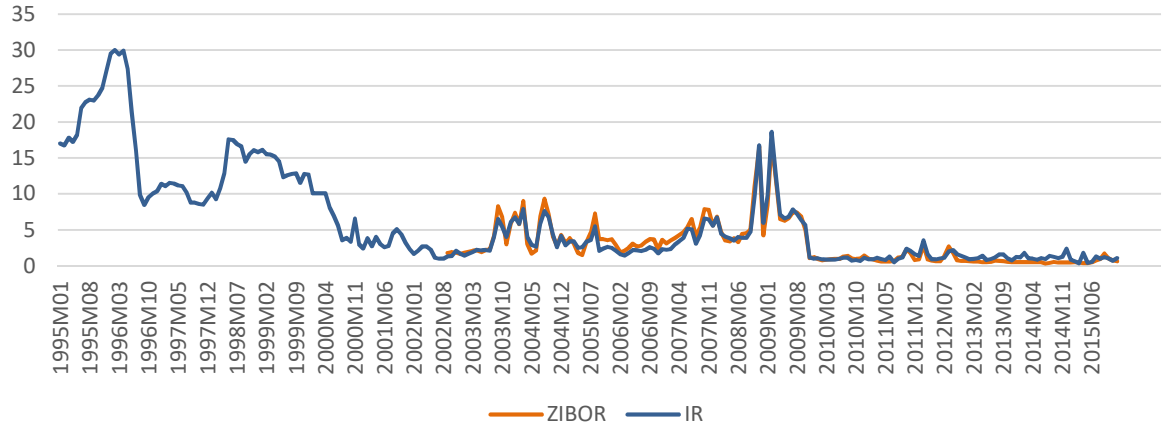

Izvor: Obrada autorice prema podacima Tržište novca Zagreb, Pregled prosječnih mjesečnih kamatnih stopa na Tržištu novca Zagreb (2018) i HNB, Kamatne stope kotirane na međubankarskom tržištu – ZIBOR (2018)

Tek je u svibnju 2000., po napuštanju administrativnog postavljanja prekonoćnih kamatnih stopa, u punom smislu profunkcioniralo tržište novca (*Galac et al., 2007*) što se odrazilo i na relativnu stabilizaciju kamatnih stopa. Konačno, 2005. uvode se operacije na otvorenom tržištu s ciljem stabilizacije kamatnih stopa na tržištu novca i povećanja važnosti kanala kamatne stope u Hrvatskoj. Snažan rast kamatnih stopa koncem 2008. i početkom 2009. javlja se pod utjecajem svjetske krize, a potom i domaće recesije (*HNB, Godišnje izvješće, 2009*). Od konca 2009. pa sve do kraja promatranog razdoblja kamatne su stope bile iznimno stabilne i niske.

Kako je već ranije istaknuto, ranija istraživanja učinkovitosti kanala kamatne stope u Hrvatskoj pokazala su njegovo nefunkcioniranje (*Vizek, 2006*). Ipak, kasnija istraživanja *(Vizek i Broz, 2007; Borozan, 2011; Borozan i Sonora, 2014)* pokazuju da kanal kamatne stope postaje (jest) statistički signifikantan iako još uvijek ne djeluje poželjnom učinkovitošću. Stoga su i dalje primarni instrument kojim se HNB koristi devizne intervencije. Rast efikasnosti kanala kamatne stope izrazito je važan u kontekstu pridruživanja Hrvatske euro zoni unutar koje ESB koristi upravo kanal kamatne stope kao primarni monetarni transmisijski mehanizam. Također, fokusiranjem monetarne politike na tečaj kune prema euru, kao nominalnom sidru, HNB je izgubio manevarski prostor za efikasnije vođenje monetarne politike[122], što bi se uvelike promijenilo efikasnijim funkcioniranjem kanala kamatne stope. U navedenim okolnostima, kako navode *Bokan et al. (2010),* HNB se nerijetko oslanja na administrativne mjere (kao što su različiti regulatorni zahtjevi) kako bi prvenstveno osigurao stabilnost bankarskog sektora i preko banaka utjecao na domaće gospodarstvo.

Monetarna politika u Hrvatskoj temeljena na tečaju kune prema euru kao nominalnom sidru pokazala se vrlo uspješnom u održavanju niske razine inflacije još od 1993. i pomogla je očuvanju stabilnosti bankarskog sektora. Ipak treba imati na umu da je riječ o malom otvorenom gospodarstvu te da je ono, kao takvo, izrazito podložno vanjskim šokovima. Provedena analiza kretanja inflacije, kao i pojedinih istraživanja inflacije u Hrvatskoj, upućuje na zaključak da je doprinos cijena nafte, odnosno naftnih šokova, kretanju inflacije u Hrvatskoj značajan.

3.3. STOPA NEZAPOSLENOSTI KAO MAKROEKONOMSKI POKAZATELJ

Promatrajući gospodarski rast kao funkciju rada i kapitala, efikasno tržište rada čini njegov temeljni preduvjet. Mnogi ekonomisti vjeruju da je kvaliteta inputa rada – vještine, znanje i disciplina radne snage – najvažniji element gospodarskog rasta (*Samuelson i Nordhaus, 2007, str. 558*). Fenomen nezaposlenosti prisutan je u većoj ili manjoj mjeri u svim ekonomijama. Visoke stope nezaposlenosti predstavljaju gospodarski teret zbog suboptimalne iskorištenosti radne snage kao ključnog proizvodnog i razvojnog resursa, a ništa manje važan nisu ni psihološki ni socijalni utjecaj na pojedince pogođene problemom nezaposlenosti i njihove

[122] I mogućnost središnje banke da djeluje kao tzv. zajmodavac posljednjeg utočišta uvelike je smanjena i ograničena na iznos deviznih pričuva jer je i glavnina obveza poslovnih banaka u stranoj valuti, primarno euru.

obitelji, odnosno sve uzdržavane članove (*Fryer i Payne, 1986*), ali i društvo za koje problem nezaposlenosti stvara veliki trošak (*Gallie et al., 2001*).

Posljednja šestogodišnja gospodarska kriza bila je okarakterizirana, između ostalog, visokim stopama nezaposlenosti koje su i uobičajeno povezane s nižim stopama ekonomske aktivnosti. Ipak, rastuća nezaposlenost, posebice mladih i dugotrajno nezaposlenih, niske stope aktivnosti i zaposlenosti, relativno visoki troškovi i niska produktivnost rada, zakonodavna i institucionalna rigidnost, relativno visok udio zaposlenih u javnom i neformalnom sektoru, te neusklađenost ponude i potražnje na tržištu rada nisu samo posljedica financijske i ekonomske krize, već i dugoročnih procesa koji uključuju i područja koja nisu isključivo povezana s tržištem rada (*Tomić, 2015*). Ipak, problem nezaposlenosti duboko je ukorijenjen u hrvatsko gospodarstvo, moglo bi se reći još i iz socijalističkih vremena.

Da bi se izvršila adekvatna analiza tržišta rada, nužno je raspolagati s kvalitetnom statističkom osnovom - transparentnim i pouzdanim podacima o pokazateljima tržišta rada. U Hrvatskoj se podaci o kretanju zaposlenosti i nezaposlenosti vode kroz administrativne izvore (HZZ – Hrvatski zavod za zapošljavanje), ali od 1996. godine i putem Ankete o radnoj snazi (ARS) koju povodi Državni zavod za statistiku (DZS) po metodologiji usklađenoj s Međunarodnom organizacijom rada – ILO (*International Labour Organisation*) i Eurostatom, čime se osigurava i metodološka usporedivost s istraživanjima u zemljama EU. Administrativni se podaci temelje na registru podataka, dok se podaci ARS-a dobivaju procjenom temeljenom na reprezentativnom statističkom uzorku privatnih kućanstava u Hrvatskoj[123]. Relevantniji su, u svakom slučaju, podaci temeljeni ARS-om[124].

Razlike u podacima o stopama nezaposlenosti, prikazane Grafikonom 3.3.1., proizlaze iz korištenja različitih izvora i obuhvata administrativnih i anketnih podataka. Iako je u promatranom periodu visok stupanj korelacije među prikazanim pokazateljima nezaposlenosti, administrativni podaci pokazuju višu stopu nezaposlenosti u odnosu na podatke temeljene na ARS-u. To je primarno posljedica postojanja neslužbenog gospodarstva (NG) i činjenice da dio stanovništva formalno prijavljenog HZZ-u kao nezaposlenog ili neaktivnog (temeljem čega se

[123] Za detalje o načinu provođenja ankete cf,; *DZS (2013*), *Anketa o radnoj snazi, Metodološke upute*

[124] Podaci o anketnoj nezaposlenosti uobičajeno se koriste za međunarodne usporedbe nezaposlenosti i smatraju se primjerenijima i pouzdanijima od podataka koji se temelje na administrativnim izvorima. Ipak, i ovdje ima niz potencijalnih problema koji također mogu narušiti stvarnu sliku na tržištu rada. Za detalje cf. *McConnell i Brue (1994),* str. 549.-550., *Kritika podataka o kućanstvima*

ostvaruje pravo na naknadu i pristup ostalim socijalnim i materijalnim pravima za nezaposlene) radi u NG-u[125]. Osim toga, kriterij nezaposlenosti po ARS-u je stroži od kriterija HZZ-a tako da sama prijava na HZZ nije dostatna da bi se osoba i putem ARS-a smatrala nezaposlenom. Procjena udjela neslužbenog u službenom gospodarstvu (u periodu od 2001. do 2007.) pokazuje da je udio neslužbene zaposlenosti u Hrvatskoj 3,59% čime Hrvatska zauzima sedmo mjestu unutar EU28; Irska, Cipar, Latvija, Španjolska, Luksemburg i Poljska imaju veće stope neslužbene zaposlenosti (*Švec, 2009*).

Grafikon 3.3.1.: Mjesečne stope nezaposlenosti u Hrvatskoj temeljem administrativnih izvora[126] i ARS-a, 1998M01-2015M12

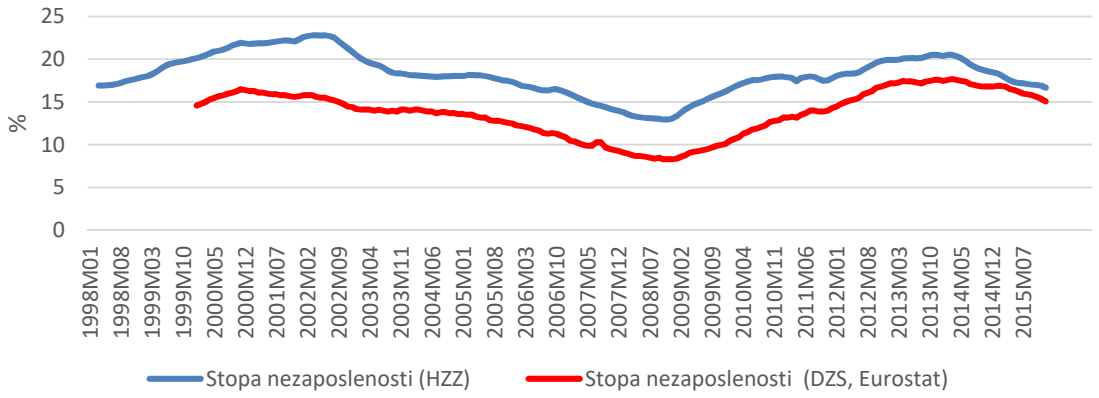

Izvor: Obrada autorice prema podacima HZZ, Stopa nezaposlenosti, (2018) i Eurostat, Harmonised unemployment rates (%) - monthly data, (2018)

Razlozi koji se nalaze u pozadini visokih stopa nezaposlenosti u Hrvatskoj su brojni i međusobno isprepleteni; stoga nerijetko ovise i o izboru autora. *Botrić (2009),* primjerice, sugerira da je veliki dio nezaposlenosti na hrvatskom tržištu rada strukturnog (a ne frikcijskog ili cikličkog)[127] karaktera, dok *Tomić (2014)* zaključuje kako neusklađenost između ponude i potražnje zanimanja nema (pre)velik utjecaj na kretanje nezaposlenosti u Hrvatskoj[128]. *Obadić i Tica (2016)* ukazuju na veliku neusklađenost između obrazovnog sustava i stvarnih potreba

[125] U odsustvu učinkovitog kažnjavanja rada u NG-u kao i nedovoljne aktivnosti u traženju posla, službeno evidentirani nezaposleni se ponašaju racionalno; maksimiziraju primanja kao i nenovčana prava iz svih raspoloživih izvora (od rada u NG-u, naknade za nezaposlenost, porezne olakšice za zaposlenu osobu koja uzdržava nezaposlenog pojedinca, jeftiniji gradski prijevoz, dječji doplatak itd. (*Crnković-Pozaić, 2002*).
[126] Vremenski je niz desezoniran TRAMO/SEATS metodom.
[127] Detaljnije o vrstama nezaposlenosti cf. *Obadić i Tica (2016),* Uzroci i vrste nezaposlenosti, str. 211.-215.
[128] Analiza neusklađenosti vještina na hrvatskom tržištu rada može se pronaći i u radovima *Obadić (2005a)* i *Matković (2011).*

tržišta rada koja je u vremenu krize (2008.-2014.) rezultirala daleko najvećim stopama rasta nezaposlenih u kategoriji visokoobrazovanih[129].

Za zbivanja na tržištu rada u prvoj polovini 1990ih moguće je pronaći objašnjenje u predtranzicijskom razdoblju, primarno velikosrpskoj agresiji na Hrvatsku koja je rezultirala velikim ljudskim i materijalnim gubitcima. Ipak, od 1995. nadalje *Družić (2004, str. 194)* smatra da više ne mogu važiti standardna tranzicijska objašnjenja, već je realnije da je riječ o posljedicama duboke gospodarske depresije. S druge strane, *Bićanić i Babić (2008)* tvrde da je za razumijevanje današnje situacije na tržištu rada od presudne važnosti uzeti neekonomske varijable i tzv. „ovisnost o putu" (*engl. path dependency*), smatrajući da su raspad bivše države, rat, tranzicija i proces privatizacije imali velik utjecaj na tržište rada koji se ogleda kroz trenutne institucije tržišta rada, demografske trendove, obrazovnu strukturu nezaposlenog stanovništva, kao i očekivanja na strani ponude i potražnje za radom.

U 1990ima, period tranzicije obilježen je i strukturnom konvergencijom tržišta rada onima zapadnoeuropskih gospodarstava. U najkraćim crtama ovi se strukturni pomaci mogu naznačiti kao usporedni procesi deagrarizacije, deindustrijalizacije i tercijarizacije (*Obadić, 2005a*). U svim je tranzicijskim zemljama naglo smanjenje gospodarskih aktivnosti, privatizacija i otpuštanje naslijeđenih viškova zaposlenika, te zatvaranje zastarjelih pogona bilo povezano s naglim padom zaposlenosti čiji su socijalni pritisci najčešće kompenzirani programima ranog umirovljenja (*Mrnjavac, 2011*). Masivno nestajanje radnih mjesta u poljoprivredi i industriji (koje se nastavilo i početkom 2000tih!) bilo je samo u rijetkim slučajevima popraćeno značajnijim kreiranjem novih radnih mjesta u uslužnom sektoru (*Obadić, 2005b*). Također, i relativno veliki porast zaposlenosti u trećem mileniju treba promatrati s oprezom. Tako *Družić (2004, str. 123)* naglašava da su gotovo sve metodološke izmjene nakon 1990. imale za cilj proširenje definicije zaposlenih, odnosno umjetno povećavanje broja zaposlenih. Na strani ponude rada također valja naznačiti pad nataliteta, emigracije i starenje stanovništva.

Međunarodna usporedba razina nezaposlenosti prema podacima ARS-a pokazuje da je u Hrvatskoj stopa nezaposlenosti dugoročno iznad prosjeka EU-a iako je svjetska kriza različito utjecala na razine nezaposlenosti po pojedinim zemljama (*Mrnjavac, 2011*). U pojašnjavanju nezaposlenosti treba uzeti u obzir činjenicu da su europska gospodarstva u velikoj mjeri

[129] Više od polovine ukupno nezaposlenih činili su visokoobrazovani.

međuovisna, iako međusobne razlike ne samo da postoje, već su nerijetko i prilično velike. O istome svjedoče i podaci na Grafikonu 3.3.2. kojim je prikazana međunarodna usporedba godišnjih stopa nezaposlenosti članica EU28, SAD-a i Japana (2000., 2008. i 2015.).

Grafikon 3.3.2.: Međunarodna usporedba godišnjih stopa nezaposlenosti unutar EU28, SAD i Japana, 2000., 2008. i 2015.

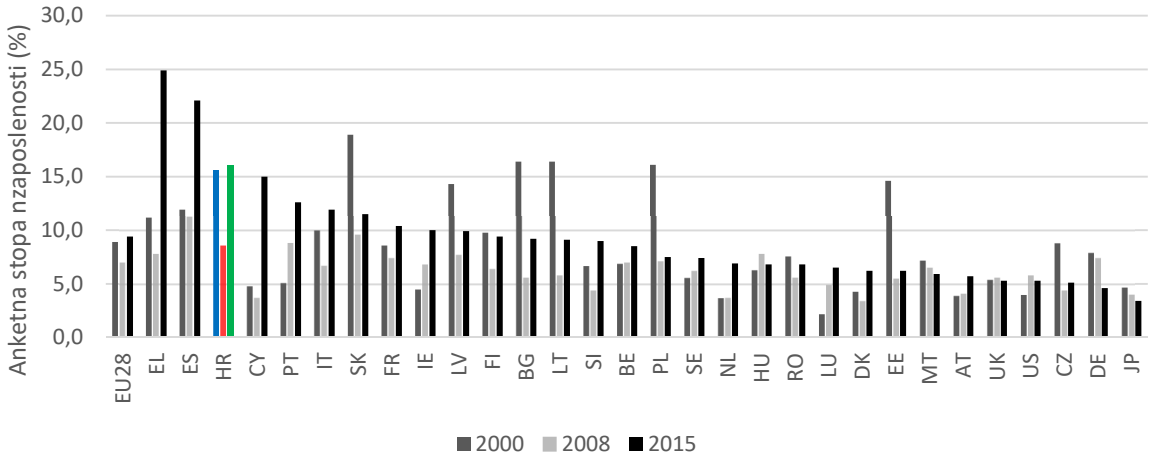

Izvor: Obrada autorice prema podacima Eurostat, Unemployment by sex and age, Annual average (2018)

Prije svega, spomenute gospodarske međuovisnosti pokazuju i puno više stope nezaposlenosti u Europi u odnosu na SAD i Japan. Štoviše, već je nekoliko desetljeća problem nezaposlenosti izraženiji u Europi nego u SAD-u i Japanu. Nadalje, usporedba gotovo svakog hrvatskog pokazatelja tržišta rada sa zemljama EU upućuje na nepovoljne rezultate. U 2015. godini Hrvatsko je gospodarstvo bilježilo treću najvišu anketnu stopu nezaposlenosti unutar EU28, odmah iza Grčke i Španjolske. Iako je tek u 2015. gospodarstvo izašlo iz dugogodišnje krize, problem visoke nezaposlenosti postojao je i puno ranije, i o njemu svjedoče i podaci za 2000. ali i 2008. kada je, iako s najnižom stopom nezaposlenosti u novijoj povijesti, nezaposlenost također bila ne samo viša od prosjeka EU28, već i od stopa nezaposlenosti ostalih post-tranzicijskih EU gospodarstava (s iznimkom Slovačke).

Uspoređujući kretanje anketne nezaposlenosti u odnosu na odabrana post-tranzicijska EU gospodarstva (*HNB, Stopa anketne nezaposlenosti u usporedbi s tranzicijskim zemljama, 2018*), podaci pokazuju da su stope nezaposlenosti u Hrvatskoj u pravilu iznadprosječne i u odnosu na ostala post-tranzicijska gospodarstva, a od 2011. nadalje i najviše u apsolutnom smislu. Više stope nezaposlenosti u periodu prije krize imale su samo Bugarska (do 2003.), Slovačka i Poljska.

Konačno, vrijedno je promotriti odnos kretanja stopa nezaposlenosti u RH u odnosu na kretanje cijena nafte (prikazan Grafikonom 3.3.3.). Već na prvi pogled može se uočiti drugačiji odnos nezaposlenosti i cijena nafte (ako se u daljnjoj analizi uopće i ispostavi da je riječ o međusobnoj povezanosti) u periodu prije i nakon krize, odnosno do i nakon konca 2008. godine. Od 2000. do 2008. godine hrvatsko je gospodarstvo, može se reći unatoč rastu svjetskih cijena nafte, pokazalo realni rast, što se usporedno odrazilo i na kontinuirani pad stope nezaposlenosti sve do konca navedenog perioda. Tek u narednom periodu, od 2009. nadalje, može se uočiti usklađeno kretanje stopa nezaposlenosti u odnosu na cijene nafte, i to u skladu s onim što sugerira teorija; usporedno s rastom cijena nafte, rasla je i nezaposlenost. Isto je tako nužno naznačiti i njihov pozitivan odnos u periodu pada cijena nafte od polovine 2014. godine nadalje, što je popraćeno smanjenjem stope nezaposlenosti. S obzirom da korelacija koja se može uočiti ovakvom analizom ne implicira uzročnost, a uvažavajući činjenicu da (prema saznanjima autorice) ne postoje značajna istraživanja utjecaja cijena nafte na nezaposlenost u RH, stvarnu prirodu odnosa cijena nafte i nezaposlenosti otkrit će tek daljnja ekonometrijska analiza.

Grafikon 3.3.3.: Mjesečne stope nezaposlenosti u Hrvatskoj temeljem administrativnih izvora i ARS-a (1998M01-2015M12) u odnosu na kretanje realne cijene nafte (u USD po barelu)

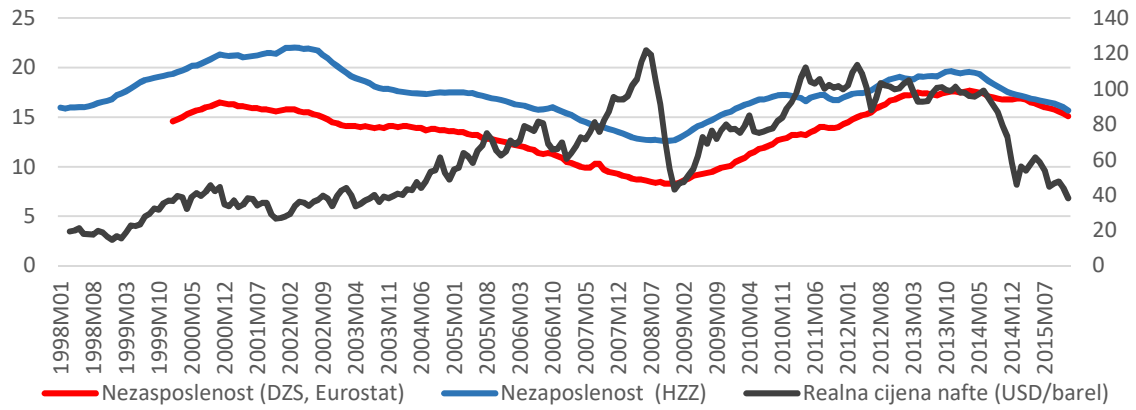

Izvor: Obrada autorice prema podacima HZZ, Stopa nezaposlenosti, (2018), Eurostat, Harmonised unemployment rates (%) - monthly data, (2018), EIA, Europe Brent Spot Price FOB (2017)

Imajući u vidu važnost koju imaju realne plaće u odnosu na kretanje stopa nezaposlenosti Grafikonom 3.3.4. prikazane su vrijednosti realnih mjesečnih neto plaća u Hrvatskoj u promatranom periodu u odnosu na kretanje broja nezaposlenih. Na prvi je pogled teško zamijetiti jasnu vezu između realnih plaća i nezaposlenosti što ide u prilog tezi o rigidnosti nadnica (*engl. sticky wages*) na hrvatskom tržištu rada. Stope rasta realnih nadnica bile su relativno visoke u drugoj polovini 1990ih (primarno zahvaljujući njihovoj niskoj razini

početkom navedenog razdoblja), nakon čega su smanjene nakon 2000. godine, dok su u vrijeme krize realne plaće uglavnom stagnirale, odnosno padale. Promatrajući pojedine periode prikazane Grafikonom 3.3.4. može se tako zaključiti da je u periodu od 1995. do 2008. godine ostvaren rast realnih plaća od gotovo 90%, nakon čega su realne plaće koncem 2015. godine bile oko 3% manje u odnosu na početak 2009. godine. Dakle, u periodu od 2009. do 2015. godine nije zabilježen nikakav rast realnih plaća.

Grafikon 3.3.4.: Broj nezaposlenih i kretanje realne neto plaće u kunama, 1995M01-2015M12

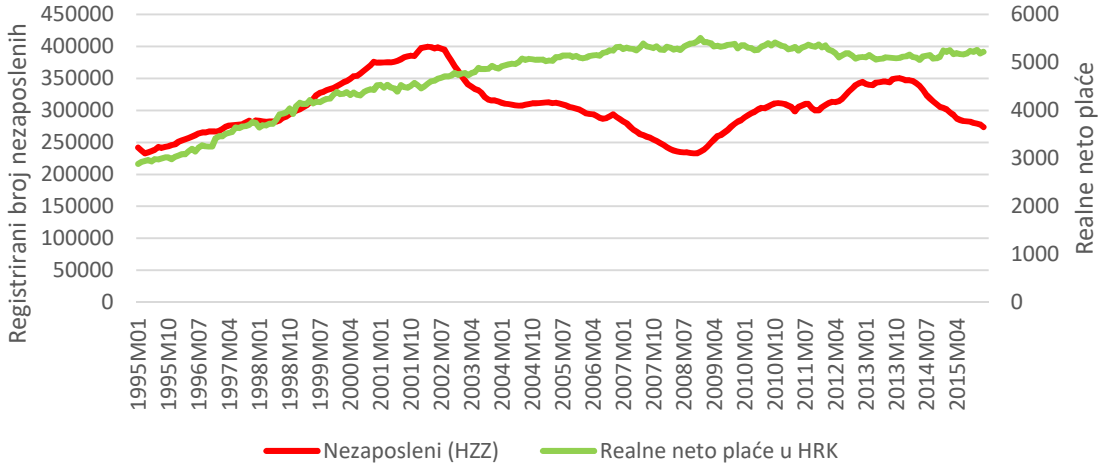

Izvor: Obrada autorice prema podacima: HZZ, Statistika, Registrirana nezaposlenost (2018), HNB, Prosječne mjesečne neto plaće (2018) i HNB, Indeksi potrošačkih cijena i proizvođačkih cijena industrije (2018). CPI za period 1995M01-1997M12 aproksimiran je uz pomoć pokazatelja cijena na malo, prema DZS, Cijene i troškovi života u 1998 (1999)

U godinama koje su prethodile globalnoj krizi, očekivanja brze konvergencije dohotka (EU razinama) dovela su do rasta plaća i cijena u Hrvatskoj, narušavajući već iznimno slabu konkurentnost domaćeg sektora razmjenjivih dobara (*engl. tradable goods*) *(Orsini i Ostojić, 2015*). Prilagodba tržišta rada padu ekonomske aktivnosti bila je sporija u odnosu na iskustva ostalih post-tranzicijskih srednjoistočnih zemalja EU članica; stoga je manjak nominalne i realne prilagodljivosti plaća doveo do znakovitog rasta nezaposlenosti u kriznim godinama.

I u vrijeme tranzicije prilagodba tržišta rada na brojne šokove ponude i potražnje prvenstveno se odvijala putem smanjivanja zaposlenosti, a ne prilagodbom plaća (*Tomić i Domadenik, 2012),* što se u literaturi najčešće objašnjava snažnom pregovaračkom moći sindikata na hrvatskom tržištu rada (*Vujčić i Šošić, 2008; Tomić i Domadenik, 2012*), iako snažnih empirijskih dokaza zapravo nema. *Kunovac i Pufnik (2015)* konstatiraju da su u godinama krize (točnije od 2010. do 2013.) prilagodbu novonastalim gospodarskim uvjetima (šoku likvidnosti i potražnje) tvrtke vršile reduciranjem troškova i to prvenstveno troškova rada, pri čemu se

prilagodba odvijala primarno kroz smanjenje broja zaposlenih (otpuštanja i neproduljivanja ugovora o radu na određeno vrijeme, kao i odgodu povećanja broja zaposlenih).

U kontekstu akademske rasprave o rigidnosti nadnica u Hrvatskoj, ispitivanje utjecaja promjene cijena nafte na nezaposlenost dodatno dobiva na važnosti. Ako se uzme u obzir da je hipoteza o rigidnosti nadnica točna, tržište rada (u smislu broja zaposlenih i nezaposlenih) bi trebalo dramatičnije reagirati na promjene cijena nafte.

Iako je fokus analize tržišta rada na fenomenu nezaposlenosti koji pokazuje stanje gospodarstva i predstavlja mjerilo socijalnih poteškoća i razlika u društvu, ograničenja samog koncepta nezaposlenosti, koji ne ukazuje na trajanje same nezaposlenosti, upućuju na promatranje zaposlenosti koja se nerijetko koristi kao bolji pokazatelj stanja na tržištu rada (*Mrnjavac, 1997*).

Zanimljivu analizu promjena zaposlenosti u poslovnom i javnom sektoru, prikazanih Grafikonom 3.3.5., nudi *Tomić (2015)*. Fluktuacije zaposlenosti su puno izraženije u privatnom sektoru koji je u periodu prije krize i bio primarni generator rasta zaposlenosti, ali je, jednako tako, u vremenu krize, u puno većoj mjeri podnio njen teret. Također, *Nikolic et al. (2014) i Nestić et al. (2015)* u svojim istraživanjima sugeriraju da su se i plaće tijekom krize značajnije prilagodile u privatnom sektoru, iako su u javnom sektoru plaće u prosjeku više nego u privatnom (*Mrnjavac, 2011; Obadić i Tica, 2016*).

Grafikon 3.3.5.: Stope promjene zaposlenosti u poslovnom i javnom sektoru

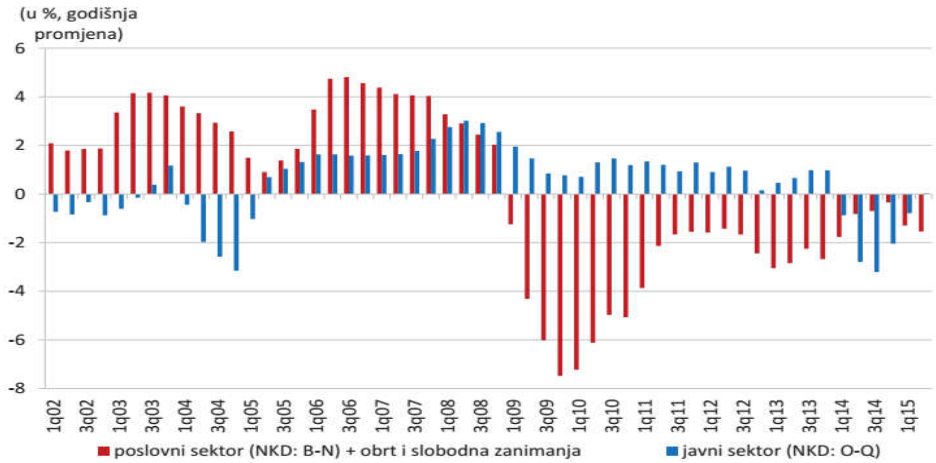

Izvor: *Tomić (2015),* str.34.

U Hrvatskoj je očito prisutan nedostatak fleksibilnosti na tržištu rada, čime se uz klasičnu nezaposlenost, koja se ogleda u nedostatku radnih mjesta, povećava i strukturna

nezaposlenost, uočljiva u neskladu strukture ponude i potražnje, jer kvalifikacije nezaposlenih ne odgovaraju zahtjevima slobodnih radnih mjesta (*Petrović Štefanac, 2012*). Dugotrajni pokazatelji visoke nezaposlenosti (kao i niske zaposlenosti) ne mogu se pojasniti samo cikličkim gospodarskim kretanjima. Riječ je o kompleksnom spletu međuodnosa na tržištu rada nastalih na ruševinama bivše države; stoga je kao objašnjenje glavnine nepovoljnih kretanja na tržištu rada važno sagledati i poteškoće u ostalim segmentima gospodarstva (*Nestić, 2015*). U pristupu rješavanju problema na tržištu rada nužno je sagledati širi gospodarski kontekst i prihvatiti činjenicu da samo dugo očekivane strukturne gospodarske reforme (a ne samo aktivne i pasivne mjere zapošljavanja) mogu rezultirati značajnijim pozitivnim pomacima.

3.4. OSOBNA POTROŠNJA KAO MAKROEKONOMSKI POKAZATELJ

Osobna potrošnja je najvažnija komponenta BDP-a, čineći preko polovinu njegove vrijednosti. Ona predstavlja dio BDP-a kojim se izravno zadovoljavaju potrebe stanovništva pri čemu se, na visokom stupnju gospodarske razvijenosti, udio osobne potrošnje zadržava na razini od cca 60% BDP-a, dok vrijednost osobne potrošnje po stanovniku značajno raste (*Denona Bogović, 2002*).

Grafikonom 3.4.1. prikazano je kretnje BDP-a i osobne potrošnje u Hrvatskoj u periodu od 1995. do 2015. Lako je uočiti da je njihovo kretanje veoma blisko, a također je vidljivo i da vrijednost osobne potrošnje, očekivano, čini veći dio ukupne vrijednosti BDP-a.

Grafikon 3.4.1.: Kretanje vrijednosti osobne potrošnje (CONS) i BDP-a od 1995:Q1 do 2015:Q4 (u milijunima kuna, u stalnim cijenama 2010.)

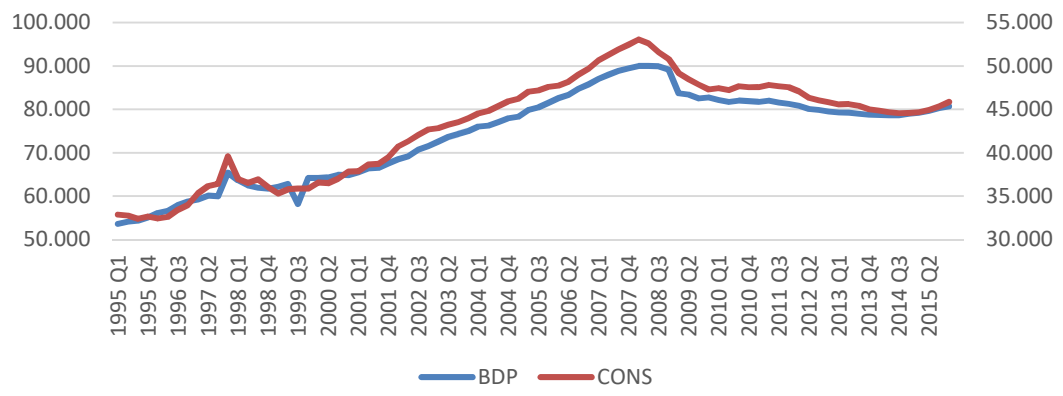

Izvor: Obrada autorice prema podacima DZS (2018b), Bruto domaći proizvod, tromjesečni obračun, stalne cijene, referentna godina 2010.

Osobito snažan rast osobne potrošnje do konca 1997. može se pojasniti završetkom rata i oporavkom potrošnje, kao i otvaranjem tržišta koje je omogućilo snažan rast potrošnje iz uvoza (djelomično i zbog neodgovarajuće strukture domaće ponude). Rastu potrošnje tih godina značajno je pridonijela i sve obilnija ponuda bankarskih i potrošačkih kredita koja se zbog otvorenosti gospodarstva i promjene preferencija prvenstveno koristila za kupnju uvoznih trajnih potrošnih dobara (*Nestić et al., 2001*). Nakon toga je, kao rezultat dovođenja fonda trajnih potrošnih dobara na zadovoljavajuću razinu i povećanja obveza servisiranja dugova, uslijedio blagi pad potrošnje do konca 1999. i, potom, kontinuirani rast sve do pojave krize 2008.

Zbog multiplikativnih efekata osobne potrošnje na proizvodnju, evidentan je doprinos rasta osobne potrošnje rastu BDP-a (u godinama njegova rasta), ali i jednako tako značajan doprinos pada osobne potrošnje smanjenju BDP-a (u periodima krize). Kako je već istaknuto, osobna je potrošnja najveća sastavnica BDP-a; stoga ni ne čudi da je njezino kretanje nerijetko presudno za kretanje ukupne gospodarske aktivnosti.

Usporedba realnih vrijednosti osobne potrošnje[130] u EU, SAD-u, Njemačkoj, Hrvatskoj i odabranim post-tranzicijskim CEE gospodarstvima[131] (1995-2015) ukazuje na usporedne razine osobne potrošnje po stanovniku u Hrvatskoj u odnosu na istu u zemljama CEE. Ipak, od početka krize, 2008. godine, osobna potrošnja po stanovniku počinje opadati i dolazi do evidentne divergencije u odnosu na ostale CEE zemlje. EU prosjek potrošnje po stanovniku znatno je viši od hrvatskog, dok je isti pokazatelj u SAD-u daleko iznad EU (pa i njemačkog prosjeka).

U Republici Hrvatskoj nisu se prije kraja 1990ih provodila značajnija sustavna i aplikativna istraživanja osobne potrošnje koja bi po metodološkom pristupu bila usporediva sa istraživanjima u razvijenim, posebno europskih zemljama. Tek prijelazom na novi, tržišni način privređivanja koji zahtijeva i standardizaciju praćenja makroekonomskih tijekova, u Hrvatskoj je DZS započeo s provedbom Ankete o potrošnji kućanstava. Anketa se od 1998. godine provodila na godišnjoj bazi (do 2011.) s primarnim ciljem dobivanja podataka o visini i strukturi

[130] Potrošnja kućanstava i neprofitnih ustanova koja služe kućanstvima (kućanstva + NPUSK) prema World Bank, World Development Indicators, Households and NPISHs Final consumption expenditure per capita (constant 2010 US$)
[131] Češka, Estonija, Litva, Latvija, Poljska, Slovačka i Slovenija.

izdataka za osobnu potrošnju kućanstava, ali i o strukturi prihoda kućanstava prema izvorima, o štednji, uvjetima života te društvenim, ekonomskim i demografskim obilježjima kućanstava. Osim što je DZS nakon 2011. smanjio frekvenciju provođenja ankete o potrošnji kućanstava na višegodišnju, čak je i poglavlje Osobna potrošnja (koje je uobičajeno sačinjavalo godišnje publikacije SLJH - Statistički ljetopis Hrvatske sve do 2013. godine) od SLJH 2014. nadalje zamijenjeno poglavljem Pokazatelji siromaštva (koje prikazuje samo pokazatelje siromaštva i materijalne deprivacije), s tim da su u SLJH 2013. objavljeni podaci o potrošnji kućanstava zaključno s 2011. godinom (jer za 2012. i 2013. podaci ne postoje).

Tablica 3.4.1. prikazuje strukturu potrošnje u Hrvatskoj prema osnovnim kategorijama potrošnje[132] od 1990. do 2014. Visoki udio egzistencijalnih dobara u prvoj polovini 1990ih ukazuje na niske razine potrošnje i općenito lošu gospodarsku situaciju. Koncem 1990ih i kasnije, početkom 2000ih, situacija se osjetno mijenja nabolje, što se može primijetiti prvenstveno po smanjenju udjela izdataka za prehranu.

Tablica 3.4.1.: Struktura osobne potrošnje u Hrvatskoj (u %)

Kategorija osobne potrošnje	**Godina**				
	1990.	**1995.**	**1999.**	**2005.**	**2014.**
Prehrana	57,5	53,0	42,4	37,2	32,8
Odjeća i obuća	14,6	11,0	7,5	7,7	6,8
Stanovanje i potrošnja energenata	6,1	18,0	13,3	13,6	16,2
Egzistencijalna dobra	**78,2**	**82,0**	**63,2**	**58,5**	**55,8**
Trajna dobra	2,0	5,0	5,9	5,1	4,5
Zdravstvo	3,3	3,0	1,8	2,3	2,9
Obrazovanje*	…	…	0,7	0,8	1,1
Kultura i rekreacija	4,4	3,0	5,7	6,2	6,0
Prijevoz i komunikacije	7,5	5,0	13,1	16,2	18,5
Ostalo	3,7	2,0	9,6	11,0	11,2
Ukupno	**100,0**	**100,0**	**100,0**	**100,0**	**100,0**

Izvor: prilagođen prema: *Denona Bogović (2002),* str.12. i *Jurčić i Čeh Časni (2017),* str.12-13.
*Izdaci za obrazovanje iskazuju se zasebno tek od 1998.

[132] Struktura osobne potrošnje kućanstava, iskazuje se pomoću 12 osnovnih skupina potrošnje, odnosno izdataka za proizvode i usluge kojima se podmiruju životne potrebe članova kućanstva, prema namjeni. Klasifikacija osobne potrošnje prema namjeni razvrstava troškove na 12 osnovnih skupina: hrana i bezalkoholna pića, alkoholna pića i duhan, odjeća i obuća, stanovanje i potrošnja energenata (uključuje izdatke za plaćanje najamnine, komunalija, električne energije, vode, plina, popravaka u stanu, proizvoda i usluga za redovito održavanje stana te iznos imputirane rente), pokućstvo, oprema za kuću i redovito održavanje, zdravstvo, prijevoz, komunikacije, rekreacija i kultura, obrazovanje, restorani i hoteli, te ostala dobra i usluge (*DZS, 2012*).

Važno je istaknuti i rast udjela potrošnje za stanovanje i energente, kao i za prijevoz i komunikacije, kategorije čiji je udio u promatranom periodu povećan više nego dvostruko. Ovo je važno s aspekta utjecaja cijene energenata, pa tako i nafte, na strukturu potrošnje. Pri tome se efekti naftnih šokova (posebice dugoročni) prvenstveno manifestiraju u promjenama strukture potrošnje (rast izdataka za energente ne uzrokuje redistribuciju raspoloživog dohotka). Ipak, da bi se stekao adekvatan uvid u strukturu osobne potrošnje, nužno ju je usporediti na razini EU, posebice u odnosu na članice usporedivih značajki - preostala post-tranzicijska gospodarstva.

Tablica 3.4.2. nudi usporedbu udjela dvaju najzastupljenijih kategorija u strukturi potrošnje (hrana i bezalkoholna pića i stanovanje i potrošnja energenata) i prijevoza te realnog BDP-a po stanovniku odabranih EU članica (u predkriznoj 2006. i kriznoj 2009. godini). Unutar tablice istaknute su zemlje s najnižim i najvišim udjelima u pojedinoj kategoriji potrošnje. Udio izdataka za hranu i bezalkoholna pića koji kod Hrvatske iznosi visokih 32% (prije i za vrijeme krize) daleko je najviši udio unutar EU u kojoj je prosječna vrijednost istog na razini 12%. Ako usporedimo Hrvatsku sa Estonijom, Slovačkom i Mađarskom, koje imaju slične razine BDP-a po stanovniku, izdaci za hranu i bezalkoholna pića su u Hrvatskoj čak dvostruko veći. Ovaj nam pokazatelj ukazuje na nepovoljnu strukturu potrošnje u odnosu na zemlje usporedivih značajki (a pogotovo u odnosu na razvijene EU članice, čiji su podaci prikazani u dnu tablice). Nadalje, izdaci za stanovanje i potrošnju energenata su u Hrvatskoj najniži i daleko ispod EU prosjeka. Ovo je po svoj prilici posljedica činjenice da u strukturu osobne potrošnje nije uključena imputirana renta, a broj hrvatskih građana koji žive u vlastitoj nekretnini je, za europske pojmove, izuzetno visok. Konačno, udio izdataka za prijevoz od 11% u Hrvatskoj je ispodprosječan u odnosu na EU prosjek od 12%. Ipak, usporedba s podatkom iz Tablice 3.4.3. ukazuje na činjenicu da je rast udjela potrošnje u kategoriji prijevoz i komunikacije ostvaren upravo u korist rasta udjela izdataka za prijevoz. Udio izdataka za prijevoz najniži je u Slovačkoj (7%), a najviši je u 2006. bio u Rumunjskoj (18%), a 2009. u Bugarskoj (16,4%).

S obzirom na fokus ovog istraživanja, Tablica 3.4.3. nudi pregled prosječne godišnje osobne potrošnje u odnosu na prosječnu mjesečnu neto plaću (i krajnje maloprodajne cijene najzastupljenijih naftnih derivata), s posebnim naglaskom na pojedine stavke izdataka za prijevoz. Izdaci za prijevoz uključuju izdatke za kupnju novih i rabljenih vozila, kupnju rezervnih dijelova, izdatke za popravak vozila, kupnju goriva i maziva. Ova skupina također uključuje i izdatke za javni prijevoz željeznicom, cestom, morem i zrakom.

Tablica 3.4.2.: Usporedba udjela u ukupnoj potrošnji u 2006. i 2009. za odabrana EU gospodarstva

Udio u ukupnoj potrošnji kućanstva i *per capita* BDP	2006.				2009.			
	Hrana i bezalkoholna pića	Stanovanje i potrošnja energenata	Prijevoz	Realni *per capita* BDP u EUR (% od EU28 prosjek)	Hrana i bezalkoholna pića	Stanovanje i potrošnja energenata	Prijevoz	Realni *per capita* BDP u EUR (% od EU28 prosjek)
Hrvatska	**32,6**	**13,7**[133]	**11,4**	**42%**	**32,1**	**14,4**	**11,0**	**42%**
Bugarska	17,7	17,8	17,0	18%	18,8	19,2	16,4	20%
Češka	14,5	24,7	10,4	57%	14,2	27,2	9,3	58%
Estonija	17,8	18,1	12,9	48%	20,2	20,3	11,3	43%
Latvija	18,9	19,8	13,5	36%	20,2	23,2	10,3	34%
Litva	23,9	14,8	15,9	34%	25,3	16,4	14,6	35%
Mađarska	16,5	19,1	15,5	40%	16,8	22,0	13,2	39%
Poljska	20,9	22,1	10,0	31%	19,4	22,7	10,9	36%
Rumunjska	29,1	20,0	18,0	22%	27,2	25,2	13,2	26%
Slovenija	14,6	19,1	15,2	68%	14,6	19,9	14,9	70%
Slovačka	17,2	26,7	7,7	42%	17,3	25,6	7,3	48%
Njemačka	10,6	24,5	14,7	121%	10,7	24,9	14,4	123%
Španjolska	12,8	18,0	12,0	94%	12,6	21,8	11,0	93%
Francuska	12,8	24,2	13,9	120%	13,0	25,3	13,6	121%
Italija	14,7	20,7	13,3	111%	14,8	22,6	12,3	106%
EU28	**12,0**	**22,9**	**13,5**	**100%**	**12,4**	**24,2**	**12,8**	**100%**

Izvor: Obrada autorice prema podacima Eurostat, Final consumption expenditure of households by consumption purpose (2018), DZS, Osnovne karakteristike potrošnje i primanja kućanstava (za godišta od 1998. do 2010.), Osnovne karakteristike potrošnje kućanstava (za 2011. i 2014.) i Eurostat, GDP per capita in PPS (2018)

Potrošnja po kućanstvu u promatranom je periodu (od 2006. do 2014.) povećana za 8,7%, što je nešto više od rasta prosječne neto plaće od 6,9%, dok su istovremeno izdaci za prijevoz porasli za čak 18,2%.Vrijedno je također sagledati i samu strukturu izdataka za prijevoz. Tako je evidentan drastičan pad prodaje vozila (o čemu će detaljnije biti riječi u narednom poglavlju) za čak trećinu kao i istovremeni porast izdataka za održavanje vozila za gotovo jednu četvrtinu. Ovi podaci upućuju na odgađanje kupnje automobila i sve veću starost voznog parka hrvatskih građana pa su tako izdaci za rezervne dijelove povećani za čak više od 50%. Sve se ovo odvijalo

[133] Podaci o udjelu potrošnje kućanstava u RH za Stanovanje i potrošnju energenata ne uključuju imputiranu rentu. Imputirana renta, prema Eurostat-ovoj metodologiji, sastavni je dio izdataka za Stanovanje i potrošnju energenata. To je pretpostavljeni iznos naknade za najam stana koju bi kućanstvo koje stanuje u vlastitom stanu, platilo kada bi isti takav stan trebalo unajmiti za potrebe svoga kućanstva. U Anketi se iznos tog podatka za kućanstva koja stanuju u vlastitim stanovima dobiva na osnovi slobodne procjene nositelja kućanstva o visini naknade koju bi kućanstvo platilo kada bi isti takav stan unajmilo za potrebe svoga kućanstva.

uz istovremeni rast cijena goriva i maziva od gotovo 20%, točnije Euro dizela za 15% i Eurosuper95 za gotovo 25%.

Tablica 3.4.3.: Prosječna godišnja osobna potrošnja po kućanstvu i izdaci za prijevoz u odnosu na kretanje prosječne nominalne plaće i cijena goriva, u kunama (tekuće cijene)

	2006.	2008.	2009.	2010.	2011.	2014.	'06./'14.	'08./'14.
UKUPNA OSOBNA POTROŠNJA	**69.457**	**74.524**	**76.188**	**75.167**	**74.941**	**81.054**	**16,7%**	**8,7%**
IZDACI ZA PRIJEVOZ	**7.923**	**8.945**	**8.363**	**8.999**	**9.702**	**10.573**	**33,4%**	**18,2%**
1. Kupnja vozila	2.373	2.226	1.900	1.588	1.597	1.497	**-36,9%**	**-32,7%**
1.1. Vozila	2.263	2.159	1.864	1.546	1.576	1.445	-36,1%	-33,1%
1.2. Ostalo (motocikl, bicikl,…)	110	67	36	42	19	52	-52,7%	-22,4%
2. Održavanje vozila	4.806	6.197	5.878	6.408	7.126	7.729	**60,8%**	**24,7%**
2.1. Rezervni dijelovi i pribor	263	370	448	431	501	569	116,3%	53,8%
2.2. Goriva i maziva	3.605	4.731	4.331	4.742	5.194	5.642	**56,5%**	**19,3%**
2.3. Održavanje i popravci	487	589	577	685	750	389	-20,1%	-34,0%
2.4. Ostale usluge za prijevoz	450	508	520	549	681	1.130	151,1%	122,4%
3. Putnički promet i usluge	744	523	586	1.003	979	1.347	81,0%	157,5%
Prosječna mjesečna neto plaća	4.602	5.177	5.311	5.342	5.441	5.534	20,2%	**6,9%**
Prosječna cijena Eurodizela	7,28	8,51	6,81	7,86	9,13	9,83	35,0%	**15,5%**
Prosječna cijena Eurosuper95	7,89	8,37	7,37	8,41	9,63	10,44	32,3%	**24,7%**

Izvor: Obrada doktorandice prema podacima: DZS; Osnovne karakteristike potrošnje i primanja kućanstava (za godišta od 1998. do 2010.), Osnovne karakteristike potrošnje kućanstava (za 2011. i 2014) HNB, Prosječne mjesečne neto plaće (2018) i Ministarstvo zaštite okoliša i energetike, Cijene naftnih derivata (2018)

Prema *Kovačević et al. (2014),* spomenuto implicira usporedno odvijanje dvaju važnih promjena na tržištu automobila. Padaju troškovi kupnje automobila (zbog pada BDP-a, ali i pogoršanja ostalih makroekonomskih pokazatelja) te rastu troškovi goriva i maziva (zbog rasta cijena naftnih derivata). Istovremeno, zbog povećanja starosti automobila, rastu troškovi popravaka i usluga što utječe na povećano izdvajanje za njihovo održavanje.

Zaključno, vrijedno je grafički promotriti i odnos kretanja osobne potrošnje u odnosu na realne cijene nafte (Grafikon 3.4.2.) uz napomenu da, prema saznanjima autorice, ne postoje empirijska istraživanja utjecaja cijena nafte na osobnu potrošnju u RH. Temeljem prikazanih podataka ne može se na prvi pogled zamijetiti nikakva značajnija povezanost među

promatranim varijablama. Ipak, pravu prirodu odnosa među istima, ako uopće postoji, otkrit će tek daljnja ekonometrijska analiza.

Grafikon 3.4.2.: Kretanje realne osobne potrošnje u odnosu na realne cijene nafte u HRK

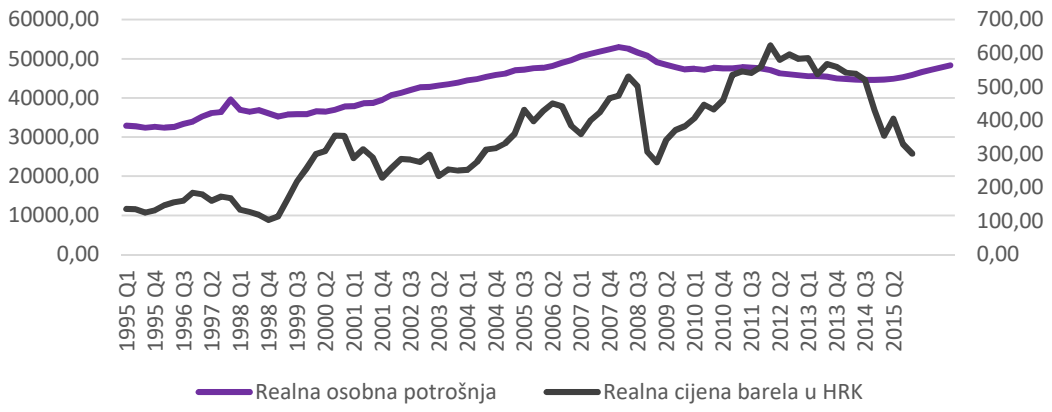

Izvor: Obrada autorice prema podacima: DZS (2018b), BDP, tromjesečni obračun, stalne cijene, referentna 2010., EIA(2017), Europe Brent Spot FOB i HNB (2018), US Federal Reseve Bank of St. Louis (2018), US PPI Srednji tečaj HNB-a

U odnosu na razvijene post-tranzicijske zemlje, Hrvatska ima lošiju strukturu potrošnje sektora kućanstva. Kućanstva su najviše trošila na egzistencijalna dobra: prehranu, odjeću i obuću te stanovanje i potrošnju energenata, ali u punoj manjoj mjeri od ostalih EU ekonomija, pa tako i post-tranzicijskih. S obzirom na važnost osobne potrošnje u BDP-u, ali i, još važnije, njenih multiplikativnih efekata na gospodarstvo (primarno proizvodni sektor), dobra vijest je da, ipak, udio potrošnje za egzistencijalna dobra u ukupnoj osobnoj potrošnji u analiziranom razdoblju pada. S obzirom na dugotrajan period krize, tek slijedi period koji će otkriti potencijalno nove pozitivne pomake u strukturi potrošnje kućanstava i, što je još i važnije, u visini potrošnje po stanovniku.

3.5. INVESTICIJE KAO MAKROEKONOMSKI POKAZATELJ

Ako gospodarski rast promatramo kao funkciju dvaju ključnih proizvodnih inputa; rada i kapitala, tada su, pored tržišta (ponude) rada, investicije ključna determinanta akumulacije kapitala, i, sukladno tome, preduvjet rasta i prosperiteta. Investicije (posebno one koje podrazumijevaju širenje poslovanja) doprinose rastu potražnje i potrošnje i stope zaposlenosti a, osim toga, rast investicija je i indikator pozitivnih očekivanja investitora glede budućih gospodarskih kretanja *(Mankiw, 2006, poglavlje 26.).*

Tablica 3.5.1 prikazuje udjele pojedinih komponenti BDP-a (po rashodnoj metodi, u stalnim cijenama 2010.) kroz period od 1995. do 2015. godine. Iako je, od pojedinih komponenti domaće potražnje, kretanjima BDP-a značajno pridonijela osobna potrošnja, i doprinos investicija bio je značajan, kako u vrijeme snažnog rasta od 2000. nadalje, tako i, nažalost, u vrijeme krize. Raspon unutar kojeg se kretao udio investicija u BDP-u je prilično širok, od svega 15,2% 1995. do 27,9% 2005. godine (najviši udio investicija u BDP-u, od 28,1%, zabilježen je 2008. godine). Usporedno s rastom BDP-a rastao je udio investicija, ali i obratno, kako se BDP smanjivao u vrijeme krize, drastično je padao i udio investicija u BDP-u.

Tablica 3.5.1.: Struktura bruto domaćeg proizvoda u Republici Hrvatskoj (rashodna metoda, % BDP-a)

Godina	Konačna potrošnja			Bruto investicije	Izvoz-uvoz	BDP
	Ukupno	Kućanstva	Država			
1995.	85,3	61,5	23,9	**15,2**	-2,1	100,0
2000.	82,9	60,1	21,3	**20,2**	-3,0	100,0
2005.	78,2	59,1	18,3	**27,9**	-6,1	100,0
2010.	79,1	58,0	20,1	**21,4**	-0,4	100,0
2015.	79,0	58,3	19,7	**18,3**	2,7	100,0

Izvor: Obrada autorice prema podacima DZS (2017a), Godišnji bruto domaći proizvod

Usporedbe udjela bruto investicija u fiksni kapital u BDP-u u Hrvatskoj, EU10 i EU28 (prema *Eurostat, Total investment to GDP ratio, 2018*), u periodu od 1995. do 2015. godine, ukazuju na viši udio investicija u BDP-u EU10 zemalja (uključujući i RH) u odnosu na EU28 prosjek. Ipak, s izuzetkom perioda od 2003. do 2005. godine, u cijelom promatranom periodu (uvažavajući heterogenost pokazatelja na razini pojedinog gospodarstva) EU10 ekonomije u prosjeku imaju više udjele investicija u BDP-u[134] od RH. S druge strane, odstupanje udjela investicija od 2010. do kraja razdoblja (između RH i EU10) posljedica je duboke i dugotrajne gospodarske krize u Hrvatskoj.

Na Grafikonu 3.5.1., koji prikazuje kretanje i postotne promjene realnog BDP-a i investicija u Hrvatskoj u periodu od 1995. do 2015. godine, lako se uočava prociklički karakter investicija.

[134] Veća zastupljenost investicija u BDP-u u EU10 može se direktno dovesti u vezi s činjenicom da je riječ o državama koje su uglavnom 2004. pristupile EU (Bugarska i Rumunjska kasnije, 2008.) pa su im već u ovom razdoblju na raspolaganju bila značajna sredstva predpristupnih fondova. Također, značajan priljev inozemnog kapitala involviran u procese privatizacije u tranzicijskim gospodarstvima, potaknut visokim kamatnim stopama i relativno jeftinom radnom snagom, u ove je zemlje krenuo i ranije od ratom zahvaćene Hrvatske. Rast investicija omogućilo je i „jačanje“ bankarskog sektora u kojem se povećava strani udio vlasništva, a čime dolazi do pojačanog priljeva stranog kapitala.

Iako se ponašaju prociklički kao i osobna potrošnja, investicije ipak pokazuju višu razinu fluktuacije; stoga su i njihove stope promjena uglavnom izraženije od stopa promjena BDP-a. U periodima realnog gospodarskog rasta, ali i pada, investicije su (s iznimkom 2000. i 2013.) bilježile rast, odnosno pad, po višim stopama od BDP-a doprinoseći na taj način njegovu rastu, odnosno padu.

Grafikon 3.5.1.: Kretanje (i % promjene) realnog BDP-a i bruto investicija u fiksni kapital (u stalnim cijenama 2010., u mil. kn)

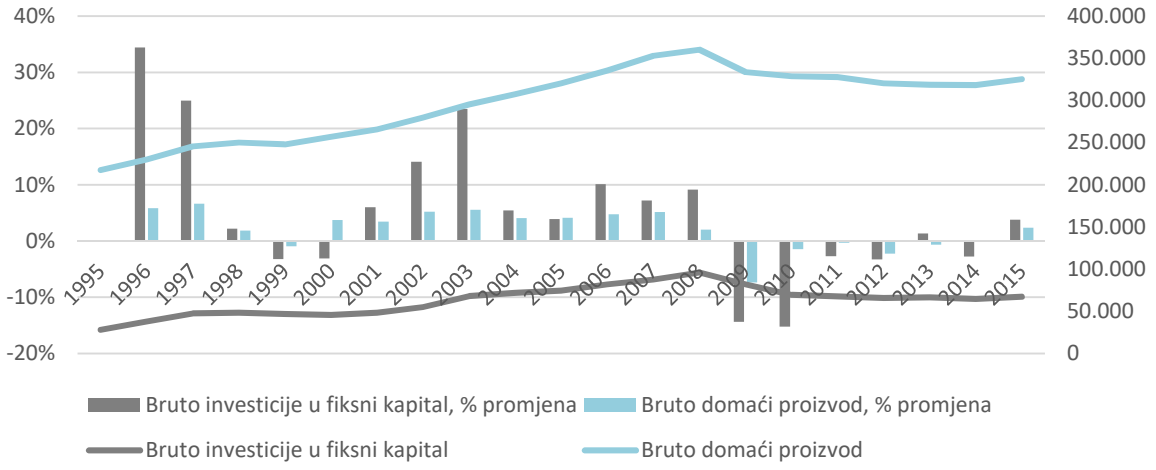

Izvor: Obrada autorice prema podacima DZS (2017a), Godišnji bruto domaći proizvod

U razdoblju od 1995. do1999. godine značajno je povećan udio kapitalnih investicija u BDP-u (*Denona Bogović, 2002*). Investicije su ponajviše potaknute poslijeratnom obnovom stambenog fonda, infrastrukture i proizvodnih kapaciteta, a u manjoj mjeri novim investicijama. Premda su investicije zabilježile znatan rast, potrebno je imati na umu da se taj rast zasnovao na veoma niskoj bazi (*Nestić et al., 2001*).

Najprosperitetnije razdoblje za hrvatsko gospodarstvo, ono između 2001. i 2008. godine, bilo je u znatnoj mjeri povezano s ostvarenom visokom vrijednosti investicija. Intenzivna izgradnja autocesta i zamah stanogradnje, kao posljedica rasta privatnih i javnih investicija, imali su snažan utjecaj na rast ukupne potražnje čime se znatno dinamizirao rast BDP-a. Kretanje privatnih investicija bilo je podržano visokim rastom domaćih kredita (*Marić et al., 2011*). U vezi s ovim razdobljem, važno je istaknuti i visoke kreditne plasmane poslovnih banaka (*HGK, 2017a*). U tom su periodu bruto investicije u fiksni kapital zabilježile najveći rast među svim kategorijama potražnje, uglavnom na štetu snažnog rasta vanjskog i javnog duga kao i kreditnih plasmana svim sektorima. Rast investicija u promatranom razdoblju bio je prisutan i u drugim tranzicijskim članicama EU, ali je u Hrvatskoj bio osjetno dinamičniji (*HGK, 2018*).

Nastupanjem svjetske financijske i gospodarske krize, poremetio se dotadašnji model financiranja investicija; uz smanjenje kapitalnih priljeva iz inozemstva i uz nemogućnost brze prilagodbe domaće štednje, nastupila je korekcija investicija, koje su 2009. godine zabilježile najviši realni pad od svih kategorija domaće potražnje (*Marić et al., 2011*). Negativni trendovi u kretanju investicija u Hrvatskoj bili su daleko izraženiji nego na razini EU, odnosno EU10 (*HGK, 2018*).

S obzirom na ograničene empirijske provjere utjecaja cijena nafte na investicije u RH, vrijedno je neposredno prije empirijske analize njihova međusobnog utjecaja grafički promotriti odnos kretanja realnih investicija u odnosu na realne cijene nafte (Grafikon 3.5.2.).

Grafikon 3.5.2. Kretanje realnih investicija (bruto investicija u fiksni kapital) u odnosu na kretanje realnih cijena nafte u HRK

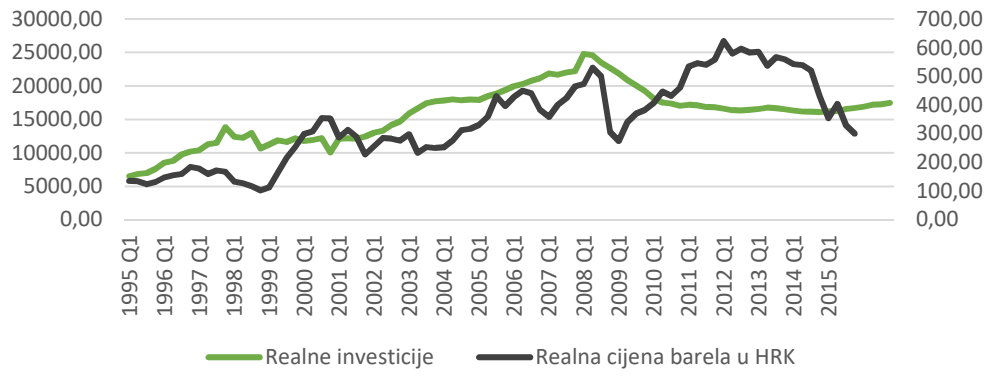

*Realna cijena nafte u HRK izračunata je umnoškom realne cijene barela nafte u USD (nominalna cijena nafte korigirana za US PPI) i srednjeg tečaja HRK/USD
Izvor: Obrada autorice prema podacima: DZS (2018b), BDP, tromjesečni obračun, stalne cijene, u milijunima HRK, referentna godina 2010, Bruto investicije u fiksni kapital, EIA(2017), Europe Brent Spot Price FOB, HNB (2018), Srednji tečaj HNB-a, US Federal Reseve Bank of St. Louis (2018), US PPI

Grafikon na prvi pogled ilustrira blago pozitivan, ali i volatilan trend kretanja kako investicija tako i cijena nafte (izraženih u kunama). Ilustrirani odnos između promatranih varijabli može sugerirati različitu prirodu njihova odnosa u vremenima realnog rasta, odnosno gospodarske recesije. Također, razlika u odnosu prije i nakon naftnog šoka 2008. godine može potencijalno biti i posljedica različitih uzroka koji su rezultirali rastom cijena nafte (kako je raspravljeno u sklopu poglavlja 2.2.). Za razliku od rasta cijena nafte od 2009. do 2012. godine i općenito njihove višegodišnje visoke razine sve do polovine 2014. godine, stabilan rast cijena nafte početkom trećeg milenija odraz je snažne globalne potražnje koja je rezultat gospodarskog rasta. I Hrvatska je u navedenom periodu uživala pozitivne stope realnog rasta pa je moguće da

zaista, na tragu zaključaka *Kiliana (2009)* i *Cashin et al. (2014)* gospodarstva, uključujući i hrvatsko, različito reagiraju na naftne šokove ovisno o njihovom uzroku.

Na koncu je vrijedno zaključno usporediti i, Grafikonom 3.5.3. prikazano, kretanje realnog BDP-a u odnosu na njegove ključne komponente; osobnu, investicijsku i državnu potrošnju, te uvoz i izvoz (roba i usluga).

Grafikon 3.5.3.: Realno* kretanje BDP-a i njegovih ključnih komponenti (rashodna metoda), 2008=100

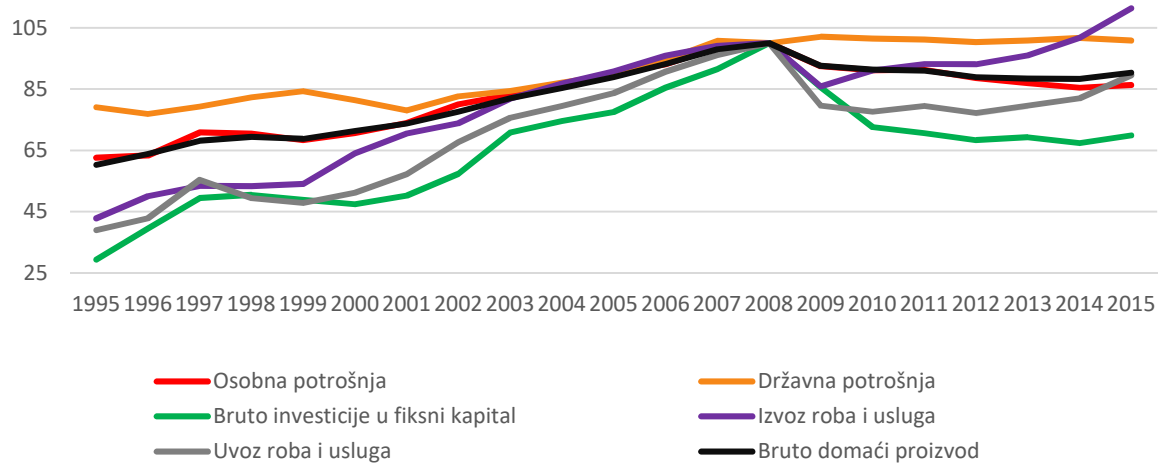

*stalne cijene, referentna godina 2010., (ESA 2010), u milijunima kuna
Izvor: Obrada autorice prema podacima DZS (2017a), Godišnji bruto domaći proizvod

Iako je osobna potrošnja najzastupljenija komponenta, njeno kretanje je daleko najbliže kretanju BDP-a, pa je crvenu liniju koja predstavlja njeno kretanje na mjestima teško i primijetiti jer je „skrivena“ ispod linije kretanja BDP-a. Obje su ove veličine „krenule“ 1995. sa 60% svoje realne vrijednosti iz 2008. da bi 2015. dosegle, 90%, odnosno 86%, iste. Najblaže oscilacije pokazala je državna potrošnja koja je do vremena krize realno povećana za 20%, a od 2008. nadalje je, zbog potrebe anticikličkog djelovanja kao i održavanja fiskalne discipline, bila gotovo nepromijenjena. Izvoz i uvoz roba i usluga više su nego udvostručeni u predkriznom razdoblju, ali je zato koncem promatranog razdoblja rast izvoza bio daleko izraženiji od rasta uvoza (što se pozitivno odrazilo na vanjskotrgovinsku bilancu zemlje) i 2015. je bio realno veći za više od 11% u odnosu na 2008. što se ne može reći za uvoz koji je bio na 90% realne vrijednosti iz 2008. Na koncu, naglasak na kretanje investicija, komponente BDP-a koja je u promatranom periodu pokazala najviši stupanj volatilnosti; najviši rast prije krize, ali i najviši pad nakon njenog početka. Realna vrijednost investicija činila je 1995. manje od trećine njihove vrijednosti iz 2008. da bi se njihova realna razina smanjila do 2015. na 70% razine iz 2008.

Investicije su imale važnu ulogu u stimuliranju gospodarskoga rasta prije krize i svakako bi morale biti jedan od ključnih čimbenika oporavka i rasta nakon nje. Investiranje, nastanak novih kapitalnih dobara (primarno strojeva i građevina), je preduvjet rasta produktivnosti rada kao i životnog standarda (*Frank i Bernanke, 2001, str. 592.*). U tom smislu, upravo bi investicije trebale biti kategorija potražnje koja bi u srednjem (i dugom) roku bila temeljni poticaj dinamiziranju rasta BDP-a. Promatrajući gospodarstvo kao cjelinu, štednja je temelj za investiranje. U uvjetima malo vjerojatnoga povratka na predkriznu strukturu i količinu priljeva inozemnoga kapitala, fokus bi se trebao usmjeriti na povećanje učinkovitosti investicija te nove izvore njihova financiranja. Za povećanje efikasnosti investicija potrebno je prije svega raditi na ubrzanju strukturnih reformi, o kojima se jako puno govori, a realno puno toga ne radi. Što se tiče novih izvora financiranja, očekuje se velik doprinos fondova Europske unije (*Marić et al., 2011*).

3.6. ANALIZA TRŽIŠTA NAFTNIH DERIVATA

Preduvjet za upoznavanje s karakteristikama tržišta naftnih derivata je poznavanje važnosti nafte u energetskoj strukturi RH. U strukturi potrošnje energije RH, sa trećinom ukupne potrošnje, prevladavaju tekuća goriva (ne uključujući prirodni plin). Navedeno ukazuje na izrazitu važnost naftnih derivata (*EIHP, Energija u Hrvatskoj 2015, str. 46*). Važnost tekućih goriva evidentna je i unutar strukture tzv. neposredne potrošnje energije[135] unutar koje tekuća goriva čine i više, oko 40%.

Pokazatelji potrošnje energije po stanovniku smještaju hrvatsko gospodarstvo na začelje ljestvice EU28 gospodarstava, s prosječnom potrošnjom energije po stanovniku čak 30% nižom od EU28 prosjeka (*EIHP, Energija u Hrvatskoj 2015, str. 49*), a slična je situacija i kada se promotri potrošnja tekućih goriva po stanovniku gdje opet Hrvatska zaostaje za EU28 prosjekom s 20% manjom potrošnjom tekućih goriva po stanovniku. Najrazvijenija europska gospodarstva (Njemačka, Francuska, Velika Britanija, Italija, Španjolska), ali i mnoga druga, imaju višu potrošnju energije i tekućih goriva po stanovniku, što znači da je uslijed očekivanih konvergencijskih procesa gospodarskog razvoja i rasta standarda hrvatskih građana realno

[135] *engl. Final Energy Consumption* – dobije se kada se od ukupne proizvodnje energije oduzmu gubitci transformacije, transporta i distribucije, pogonskih postrojenja i neenergetske potrošnje.

očekivati i rast potrošnje energije kao i tekućih goriva. Shodno navedenom, indeksi energetske intenzivnosti[136] u RH u periodu od 1995. do 2015. ukazuju na pad energetske intenzivnosti cjelokupnog gospodarstva od gotovo 15%, dok se istovremeno bilježi rast energetske intenzivnosti u sektoru transporta od gotovo 20% (*EIHP, Energija u Hrvatskoj 2015, str. 208*).

S obzirom na ranije naznačenu važnost energije kao preduvjeta gospodarskog rasta, nameće se i potreba isticanja problematike uvozne ovisnosti o istoj. Uvozna ovisnost o energiji sve je izraženija (u EU, ali i u RH) čemu ponajviše doprinosi upravo uvozna ovisnost o nafti i naftnim derivatima. U periodu od 1990. do 2010. godine uvozna ovisnost o nafti i naftnim derivatima u RH rapidno je porasla sa 42,8% na 80,4% (*Eurostat, Oil imports dependency, 2018*)[137]. Uvoz nafte i naftnih derivata čini zajedno preko dvije trećine ukupnog uvoza energije (*EIHP, Energija u Hrvatskoj 2015, str. 41*) pri čemu se, u proteklom desetljeću, smanjio uvoz nafte, a povećao uvoz naftnih derivata. Navedeno je posljedica ponajviše smanjenja rafinerijskih aktivnosti u Hrvatskoj, ali i porasta broja energetskih subjekata na maloprodajnom tržištu naftnih derivata koji naftne derivate nabavljaju na stranom tržištu jer ne posjeduju domaće rafinerijske kapacitete. Važno je također naglasiti i kako naftni derivati čine čak 70% izvoza energije iz RH (*EIHP, Energija u Hrvatskoj 2015, str. 44.*) jer hrvatske rafinerije plasiraju svoje proizvode na strano tržište. Evidentno je, dakle, strukturno nepodudaranje potražnje za naftnim derivatima i ponude istih, zbog čega je u vanjskotrgovinskoj razmjeni istovremeno prisutan uvoz i izvoz naftnih derivata.

Prema podacima Hrvatske gospodarske komore (*HGK, 2015*), u 2014. je godini izvoz naftnih derivata činio 9,0% vrijednosti ukupnog robnog izvoza, dok su uvoz sirove nafte i naftnih derivata činili oko 12,0% ukupne vrijednosti robnog uvoza. Kada je riječ o izvozu, upravo naftni derivati predstavljaju jedan od važnijih izvoznih proizvoda RH (čiji se udio u vrijednosti robnog izvoza kreće na razini od oko 10%). Sirova nafta i naftni derivati godinama su bili među najzastupljenijim proizvodima i u robnom uvozu, a u razdoblju od 2010. do 2014. i najzastupljeniji. Promatrajući period od 1995. do 2015. godine, vrijednost uvoza sirove nafte i naftnih derivata gotovo je do konca ovog perioda iznosila oko 10% vrijednosti robnog uvoza[138], pri čemu je udio uvoza sirove nafte konstanto opadao, a uvoza naftnih derivata rastao. Vrijednost uvezene sirove nafte u 2000. godini bila je 16,4 puta veća od vrijednosti uvezenih

[136] Potrošnja energije po jedinci BDP-a u promatranom sektoru
[137] U istom periodu navedeni je pokazatelj na razini EU28 povećan sa 80,1% na 84,5%.
[138] 2010. godine ovaj je udio iznosio čak 14,6%.

derivata, a 2014. godini tek 1,1 puta veća (*HGK, 2015*). Iz svega navedenog može se zaključiti da je u posljednjih petnaestak godina (od 2000. do 2015.) vanjska trgovina sirovom naftom i naftnim derivatima znatno više poticala rast uvoza nego rast izvoza. U skladu s tim, povećan je i utjecaj te trgovine na rast ukupnoga robnog deficita.

Promatrajući strukturu potrošnje naftnih derivata po sektorima, prikazanu Grafikonom 3.6.1., može se uočiti da u strukturi potrošnje (promatrajući cijeli period) prevladava potrošnja u prometu. Sektor prometa s, još uvijek, slabim mogućnostima supstitucije pogonskih goriva, apsorbira više od dvije trećine ukupne potrošnje naftnih derivata (*EIHP, Energija u Hrvatskoj 2015, str. 82*), pri čemu je važno istaknuti da se upravo u cestovnom prometu troši čak 90% ukupne energije koja se troši u svim vrstama prometa (*EIHP, Energija u Hrvatskoj 2015., str. 98*).

Grafikon 3.6.1.: Ukupna potrošnja derivata nafte u Republici Hrvatskoj

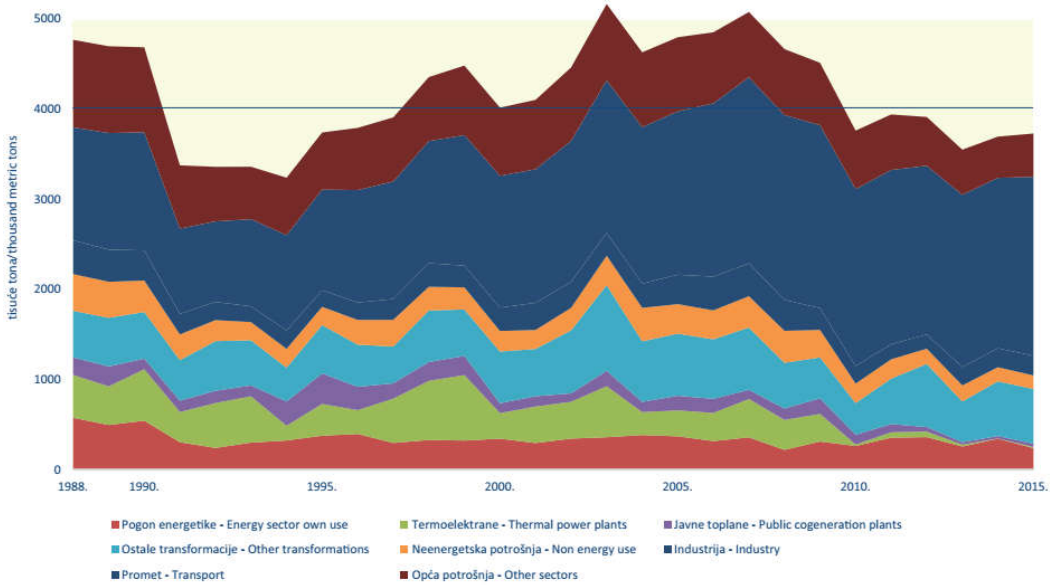

Izvor: EIHP, Energija u Hrvatskoj, 2015, str. 114.

Potrošnja neposredne energije u prometu (prikazana Grafikonom 3.6.2.) porasla je za čak 80% u periodu od 1995. do 2015. godine, te pokazuje kako gotovo 90% potrošnje čine motorni benzini i dizelska goriva. Pri tome je evidentno smanjenje udjela motornih benzina (sa 50% 1995., na 26% 2015. godine) i izražen rast udjela dizelskih goriva (sa 45% 1995., na 62% 2015. godine). Dok se udio dizelskih automobila u najrazvijenijim europskim gospodarstvima

smanjuje (EU15[139]), u Hrvatskoj udio registriranih novih osobnih automobila na dizelski pogon i dalje raste (u 2017. godini udio je iznosio 54,82%).

Grafikon 3.6.2.: Potrošnja neposredne energije u prometu

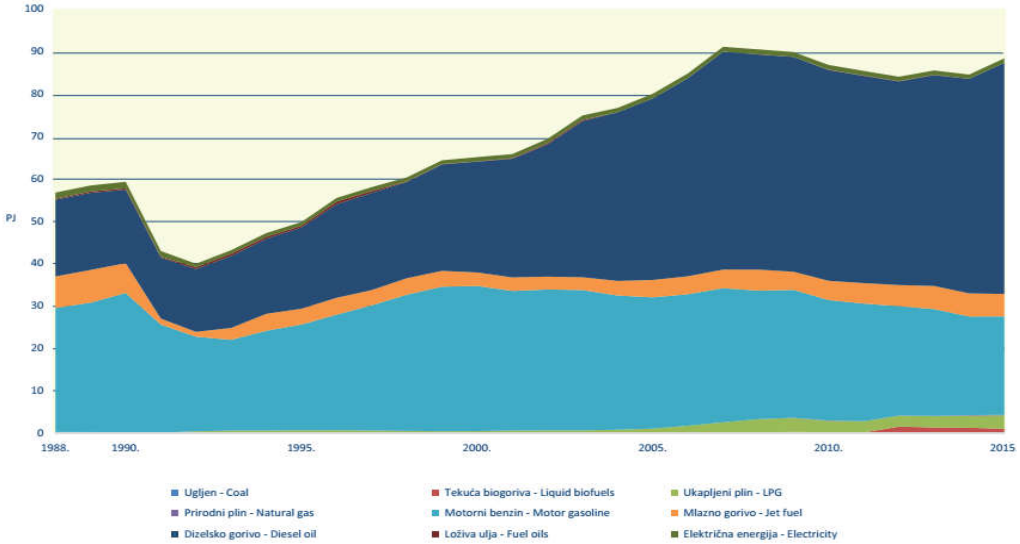

Izvor: EIHP, Energija u Hrvatskoj 2015, str. 95.

Ovaj je trend vidljiv iz Grafikona 3.6.3. koji prikazuje prodaju novih automobila u RH prema vrsti pogonskog goriva od 2007. do 2017. godine[140]. Ukupna je prodaja novih automobila drastično pala kao odraz gospodarske krize, pri čemu je 2013. godine iznosila 27 802 automobila, ili svega 31% ukupne količine prodanih automobila u 2008. godini. Od 2013. godine bilježi se kontinuirani rast prodaje novih automobila, no ukupna je prodaja još uvijek daleko od pred-kriznih razina. Ove je podatke nužno sagledati u širem kontekstu istovremene pojave krize i iznimnog rasta cijena nafte (naftnih derivata), što je u velikoj mjeri utjecalo na iznose i strukturu izdataka za prijevoz kućanstava, o čemu je već i bilo riječi (vidjeti Tablicu 3.4.3.). Unatoč tome, analizirajući vezu cijena naftnih derivata i ukupne i strukturne promjene novoregistriranih osobnih automobila od 2000. do 2011. na području RH, *Kovačević et al.*

[139] Udio dizelskih osobnih automobila u EU15 počeo je opadati počevši od 2011. godine kada je dosegnuo svoju najvišu vrijednost (56,1%) da bi 2017. iznosio 44,8% (EAMA – European Automobile Manufacturer Association, Share of Diesel in New Passenger Cars, https://www.acea.be/statistics/tag/category/share-of-diesel-in-new-passenger-cars, pristup: 20.08.2018.)

[140] Osim vozila na benzinski i dizelski pogon, u grafikon je uvrštena (jedva primjetna) kategorija „ostalo“ koja uključuje električna i hibridna vozila te vozila na pogon ukapljenim naftnim plinom . Udio navedene kategorije automobila iznosio je skromnih 1,7% 2017. godine pri čemu su električni automobili značajno podzastupljeni. Ovaj je podatak važan s aspekta mogućnosti (ili možda bolje reći ekonomske isplativosti) supstitucije fosilnih goriva u prometu. Čak i unutar kategorije „ostalo“ daleko su zastupljenija vozila na plinski ili hibridni pogon (koji predstavlja kombinaciju benzinskog ili dizel motora i elektromotora), dakle opet vozila koja koriste fosilna goriva u odnosu na isključivo električni pogon.

(2014) zaključuju da provedena analiza ne pokazuje postojanje veze između godišnjih kretanja cijena benzina i dizela i ukupno novoregistriranih automobila.

Grafikon 3.6.3.: Prodaja (broj prvih registracija) novih automobila prema vrsti pogonskog goriva

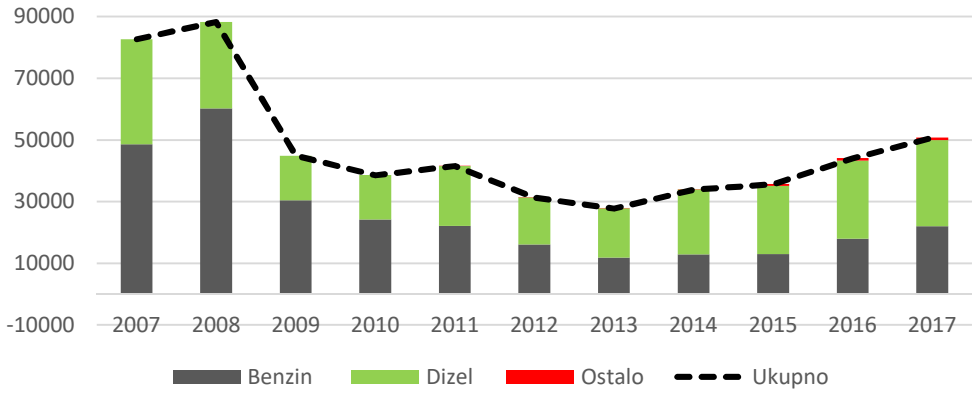

Izvor: Obrada autorice prema mjesečnim izvješćima agencije Promocija plus o prodaji novih osobnih vozila u RH

Prema podacima Europskog udruženja proizvođača automobila (*engl. European Automobile Manufacturer Association*) o broju registracija novih vozila na 1000 stanovnika u EU u 2017. godini[141] Hrvatska se nalazi pri samom dnu ljestvice sa svega 12,1 registracija na 1000 stanovnika (a 2017. je broj registriranih novih vozila u RH gotovo udvostručen u odnosu na 2013.!) što ne čini niti polovinu EU28 prosjeka koji je iznosio 29,6 novih registracija na 1000 stanovnika u 2017. godini. Treba svakako napomenuti i da navedeni podaci isključuju uvoz automobila koji je izraženiji od kupnje novih automobila, što za posljedicu ima i veću starost voznog park. 2017. godine prosječna starost automobila u RH iznosila je 14 godina (*CVH, 2018*) što je čak 3 godine više u odnosu na EU28 prosjek za istu godinu (*EAMA, 2018*). Kada se u obzir uzme cjelokupan vozni park hrvatskih građana on je, osim po starosti, i po broju registriranih automobila na začelju ljestvice EU28, sa svega 416 registracija na 1000 stanovnika u odnosu na EU28 prosjek od 587 automobila (lošije je stanje samo u Mađarskoj, Latviji i Rumunjskoj; *EAMA, 2018*). S obzirom na navedeno, a očekujući približavanje EU28 prosjeku, za očekivati je rast broja automobila u RH koji za sobom vuče i rast potrošnje naftnih derivata.

Konačno, nekoliko riječi o tržištu maloprodaje naftnih derivata u RH. Jako je teško dobiti uvid u prihode energetskih subjekata na tržištu[142], a čak i kada je to moguće, teško je razlučiti izvor

[141]Europsko udruženje proizvođača automobila, European Automobile Manufacturer Association, Statistics https://www.acea.be/statistics/tag/category/per-capita-registrations, pristup: 20.08.2018.
[142] Prilog 1 – Rješenje Agencije za zaštitu tržišnog natjecanja o odbijanju zahtjeva za pristup informacijama o tržišnim udjelima poduzetnika – sudionika na maloprodajnom tržištu naftnih derivata u Republici Hrvatskoj

prihoda (primjerice kod INA-e[143]), kao i doprinos pojedinog proizvoda/derivata u ostvarivanju istog. Kako bi se odredila struktura tržišta maloprodaje naftnih derivata, zbog navedenih se ograničenja nerijetko koristi broj benzinskih postaja kao procjenitelj tržišnog udjela.

Ukupan broj benzinskih postaja u RH u periodu od 1995. do 2015. (prikazan podacima unutar Tablice 3.6.1.) porastao je sa 526 na 826, odnosno za 57%. Ono što je zanimljivije jest da je INA d.d. zadržala gotovo isti broj benzinskih postaja i još uvijek čini najjačeg „igrača" na tržištu maloprodaje u RH, dok je gotovo cjelokupan broj novootvorenih benzinskih postaja u vlasništvu ostalih energetskih subjekata ovlaštenih za maloprodaju derivata. Ovaj je pokazatelj interesantan jer se vrlo često koristi za analizu koncentracije na tržištu i temeljem navedenih podataka može se nedvojbeno zaključiti da je tržišni udio INA-e u promatranom periodu smanjen u korist „novih" subjekata na tržištu.

Tablica 3.6.1.: Ukupan broj benzinskih postaja u RH prema vlasništvu (1995. - 2015.)

Vlasništvo	1995.	2000.	2005.	2010.	2015.	95./15.
INA d.d.	378	402	418	413	382	1,06%
Ostali	148	223	313	396	444	200,00%
Ukupno	526	625	731	809	826	57,03%

Izvor: Energija u Hrvatskoj, EIHP, razna godišta

Pojava novih subjekata na maloprodajnom tržištu javlja se usporedno s porastom udjela naftnih derivata u uvozu, što je posljedica činjenice da se novi subjekti ne bave rafinerijskim aktivnostima u RH (one su ograničene isključivo na INA-u), već naftne derivate koje prodaju na hrvatskom tržištu mahom uvoze. Tržište naftnih derivata u RH karakteristično je oligopolističko tržište sa značajnim udjelom nekolicine poduzeća, što je i svojstveno ovakvim tržištima (*Butigan, 2007*). Prema podacima prikupljenim u istraživanju Agencije za zaštitu tržišnog natjecanja (AZTN) za 2014. godinu, pet poduzetnika na hrvatsko tržište stavljalo je

[143] INA je osnovana 1. siječnja 1964. godine. 1990. godine prelazi u državno vlasništvo, a 1993. postaje dioničko društvo. Mađarskoj naftnoj kompaniji MOL 2003. godine prodano je 25% plus jedna dionica čime je MOL postao Inin strateški partner, a INA, d.d. postaje dijelom integriranog regionalnog partnerstva u industriji nafte i plina koji čine MOL, INA, d.d., Slovnaft i MOL Petrochemicals (TVK). Dvije godine kasnije, 2005., 7% dionica Ine preneseno je na Fond hrvatskih branitelja Domovinskog rata i članova njihovih obitelji. Vlada RH 2007. godine donijela je odluku o prodaji do najviše 7% dionica društva INA – Industrije nafte, d.d. zaposlenicima i ranijim zaposlenicima. Hrvatska agencija za nadzor financijskih usluga objavila je u rujnu 2008. rješenje kojim odobrava objavljivanje ponude MOL-a za preuzimanjem javnog dioničkog društva Ine, nakon čega je MOL-ov udio u vlasništvu porastao na 47,16 % ukupnog temeljnog kapitala. Krajem 2010. MOL je izvršio dodatnu ponudu, kojom mu je udio porastao na 47,26% temeljnog kapitala društva INA, d.d. Vlasnička struktura INA-e na dan 31. prosinca 2017. je sljedeća: MOL - 49,08 %, Republika Hrvatska - 44,84 %, Institucionalni i privatni investitori – 6,08 % (*INA; Godišnje izvješće 2017*).

više od 90% svih goriva; najveća hrvatska naftna kompanija - INA, Petrol, Lukoil Croatia, Tifon i Crodux Derivati Dva.

3.6.1. Cijene naftnih derivata

Cijene naftnih derivata sastoje se od nekoliko komponenti; primarno cijene nafte, odnosno samog derivata, marže, te trošarina i PDV-a. S obzirom na uvoznu ovisnost o nafti, cijena derivata ovisi i o deviznom tečaju kune u odnosu na američki dolar, valutu kojom se na međunarodnim tržištima kupuje nafta, odnosno njeni derivati. Marža u pravilu obuhvaća troškove transporta i osiguranja, trošak rafiniranja/prerade sirove nafte (ako se radi o energetskom subjektu koji samostalno vrši preradu derivata), te troškove skladištenja i distribucije proizvoda sve do prodaje krajnjem korisniku. Na cijenu derivata uvećanu za maržu dodaju se zakonom propisane trošarine nakon čega se na cjelokupan iznos obračunava PDV.

Tržište naftnih derivata u Republici Hrvatskoj u potpunosti je liberalizirano, odnosno, cijene slobodno određuju energetski subjekti koji djeluju na maloprodajnom tržištu naftnih derivata. Trenutno važeći Zakon o tržištu nafte i naftnih derivata donesen u veljači 2014. (NN 19/14, 73/17) svojim je stupanjem na snagu dokinuo primjenu dotada važećeg Pravilnika o utvrđivanju najviših maloprodajnih cijena naftnih derivata (NN 37/11, 145/12, 18/13, 62/13, 109/13). Navedeni je pravilnik od 2012. godine definirao način obračuna, objave i primjene najviših maloprodajnih cijena bez poreza i trošarina, po litri naftnog derivata (benzina, dizelskih goriva te plinskih ulja) za 14-dnevno obračunsko razdoblje po zadanoj formuli. I u razdoblju koje je prethodilo ovom, formiranje maksimalne cijene naftnih derivata definirali su pravilnici/uredbe o utvrđivanju cijena naftnih derivata[144].

U Hrvatskoj je, dakle, na maksimalne maloprodajne cijene naftnih derivata (motornih benzina, dizelskih goriva te plinskih i loživih ulja) sve do veljače 2014. i donošenja novog Zakona o tržištu nafte i naftnih derivata (NN 19/14) utjecala država određujući maksimalnu maloprodajnu cijenu za tzv. obračunsko razdoblje (uglavnom 14 dana). Bila je propisana maksimalna dopuštena promjena maloprodajne cijene (koja je varirala od 2% do 6%, ovisno o tome idu li korekcije na višu ili nižu cijenu) pojedinog naftnog derivata na dan obračuna u odnosu na

[144] Pravilnik o utvrđivanju cijena naftnih derivata, NN 46/10; Pravilnik o utvrđivanju cijena naftnih derivata, NN107/09; Pravilnik o utvrđivanju cijena naftnih derivata, NN 112/03; Uredba o određivanju najviše razine cijena naftnih derivata (NN 2/01).

prethodno obračunsko razdoblje. Time je bila ograničena fluktuacija cijena između obračunskih razdoblja. Unutar obračunskog razdoblja, energetski subjekti mogli su prodavati naftne derivate po cijenama koje su mogle biti niže, ali nikako više od maksimalnih. Ipak, cijene derivata (bez poreza i trošarina) usko su pratile cijenu nafte, dakle „formula“ za određivanje krajnje cijene derivata je bila tržišno utemeljena.

Premda se formula za izračun maksimalnih cijena naftnih derivata mijenjala izmjenama pravilnika, u izračunu se za obračunsku osnovu uvijek uzimala cijena naftnih derivata na Mediteranu[145], a ne cijena sirove nafte. Ipak, uvažavajući naizgled ograničen manevarski prostor za slobodno kreiranje cijena, grafikon koji usporedno pokazuje prosječne mjesečne cijene (bez poreza i trošarina) dvaju najzastupljenijih derivata (Eurosuper95 i Euro dizel) i cijena nafte (vidjeti Grafikon 3.6.1.1.) ukazuje na izrazito blisko kretanje cijena naftnih derivata na hrvatskom tržištu u odnosu na kretanja svjetske cijene nafte. Ovo ni ne čudi s obzirom da su formule za izračun maksimalne cijene naftnih derivata kao osnovicu za izračun uzimale cijene naftnih derivata s mediteranskog tržišta koje su usko pratile kretanje svjetske cijene nafte.

Grafikon 3.6.1.1.: Cijena nafte (Brent), Euro dizela i Eurosuper95 bez poreza i trošarina(u kn/l)

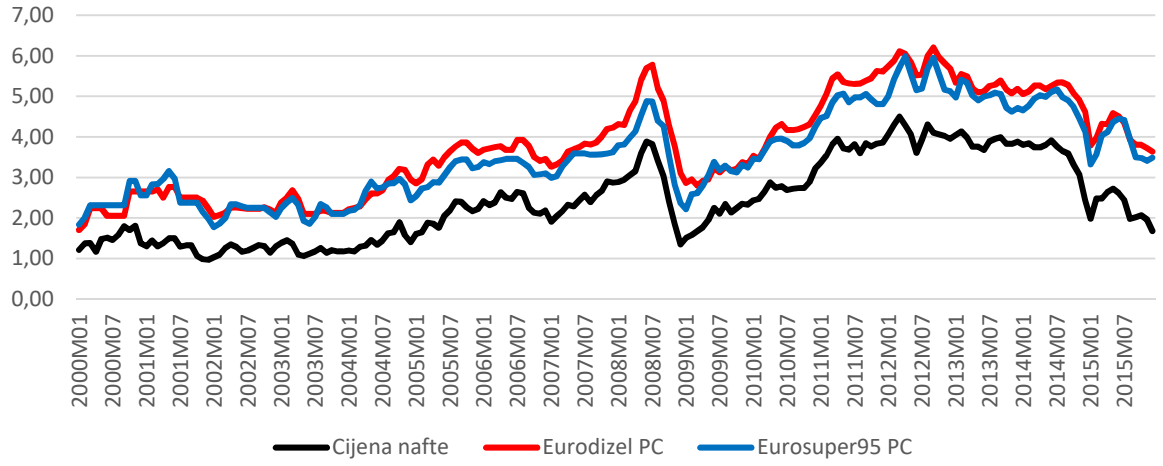

Izvor: Obrada autorice prema podacima EIA, Europe Brent Spot Price FOB (2017), HNB, Srednji tečaj HNB-a (2018)i Ministarstvo zaštite okoliša i energetike, Cijene naftnih derivata (2018)

Po ukidanju Pravilnika (NN 19/14) u veljači 2014. godine, Agencija za zaštitu tržišnog natjecanja provela je istraživanje tržišta naftnih derivata s naglaskom na tržište maloprodaje i

[145] Osnovu za obračun prodajnih cijena naftnog derivata za obračunsko razdoblje činila je prosječna cijena pojedinog naftnog derivata na mediteranskom tržištu (srednja vrijednost burzovnih kotacija Mediterranean Cargoes CIF Med Genova/Lavera) pretvorena u kune prema tečaju američkog dolara u istom razdoblju.

veleprodaje motornih goriva u Hrvatskoj (veljača 2014. - veljača 2015.) [146]. Ukidanjem Pravilnika stvoreni su uvjeti za potpuno slobodno određivanje cijena na svakoj benzinskoj postaji i češće promjene cijena naftnih derivata. Iako zakonski postoji mogućnost dnevne promjene cijena, prema istraživanju AZTN-a, korekcija cijena naftnih derivata i dalje je u pravilu slijedila u određenim vremenskim intervalima (najčešće jedanput tjedno i to utorkom). Zaključak istraživanja je da, u razdoblju kada je istraživanje provedeno, u Hrvatskoj nisu postojali pokazatelji koji bi nakon liberalizacije ukazivali na značajne promjene marži trgovaca (koje u strukturi maloprodajne cijene iznose 5-10%). Međutim, primaran utjecaj na formiranje maloprodajnih cijena imaju inputi na koje trgovci u pravilu ne mogu utjecati – nabavna cijena goriva, trošarine i porezi.

Rezultati istraživanja pokazali su i kako se cijena goriva u međusobnoj trgovini između poduzetnika u vertikalnom lancu opskrbe (proizvodnja - veleprodaja - maloprodaja) u pravilu temelji na kotaciji Mediterranean cargoes CIF Med (Genova/Lavera) iz Platt's European Marketscana, upravao onoj kotaciji koja je svojedobno i bila propisana kao element u formuli određivanja cijena naftnih derivata. Istraživanje je također pokazalo i da u nabavi goriva postoji značajan udjel dobavljača sa sjedištem izvan Hrvatske. Maloprodajne cijene goriva različitih poduzetnika u jednakim vremenskim razdobljima bilježile su određene, ne značajne, razlike u cijenama, prvenstveno kao odraz različitih marži. S obzirom da marže čine najmanji udjel u konačnim cijenama goriva i razlike u cijenama su neznatne. Promjena cijena, pak, primarno prati promjenu CIF Med kotacija prema Platt's European Marketscanu. Konačno, rezultati AZTN-ovog istraživanja pokazuju kako se u analiziranom periodu u Hrvatskoj, kao i u drugim zemljama u okruženju, bilježi fenomen asimetrije u brzini prilagodbe cijena naftnih derivata cijenama nafte (*engl. "rockets and feathers"*).

Nešto kasnije istraživanje HNB-a o cjenovnoj asimetriji naftnih derivata, dizela i motornog benzina u Hrvatskoj za razdoblje od veljače 2014. do prosinca 2018. godine, ukazuje na nepostojanje cjenovne asimetrije u prilagodbama cijena dizela cijenama nafte, dok se s druge strane navodi moguće postojanje pozitivne cjenovne asimetrije u prilagodbi cijena motornih benzina, ali tek uz 10%tnu razinu signifikantnosti. Zbog toga se zaključuje da postoje naznake

[146] http://www.aztn.hr/6930/

asimetrije, ali da ista nije statistički značajna (*HNB, Makroekonomska kretanja i prognoze, 2018*).

Grafikon 3.6.1.2. prikazuje prosječne mjesečne cijene nafte i krajnje maloprodajne cijene Euro dizela i Eurosuper95 implicirajući nešto slabiju vezu između svjetskih kretanja cijena nafte i domaćih kretanja maloprodajne cijene najzastupljenijih naftnih derivata. Za očekivati je da su maloprodajne cijene u cijelom periodu primjene Pravilnika o utvrđivanju najviših maloprodajnih cijena naftnih derivata (NN 145/12, 18/13, 62/13 i 109/13) i bile jednake maksimalno mogućima. Valja napomenuti i da su na oba grafikona (3.6.1.1. i 3.6.1.2.) prikazane cijene nafte denominirane u kunama; stoga su odstupanja maloprodajnih cijena derivata od kretanja svjetske cijene u većoj mjeri posljedica promjene poreza i trošarina na naftne derivate, odnosno, ne mogu se opravdati kretanjima tečaja kune u odnosu na američki dolar. Krajnje maloprodajne cijene Eurosuper95 su, u pravilu, veće od cijena Euro dizela što je direktna posljedica primjene viših trošarina na bezolovni motorni benzin u odnosu na dizelska goriva.

Grafikon 3.6.1.2.: Prosječne mjesečne cijene nafte (Brent u kn/bbl, lijeva os), Euro dizela i Eurosuper95 (u kn/l, desna os)

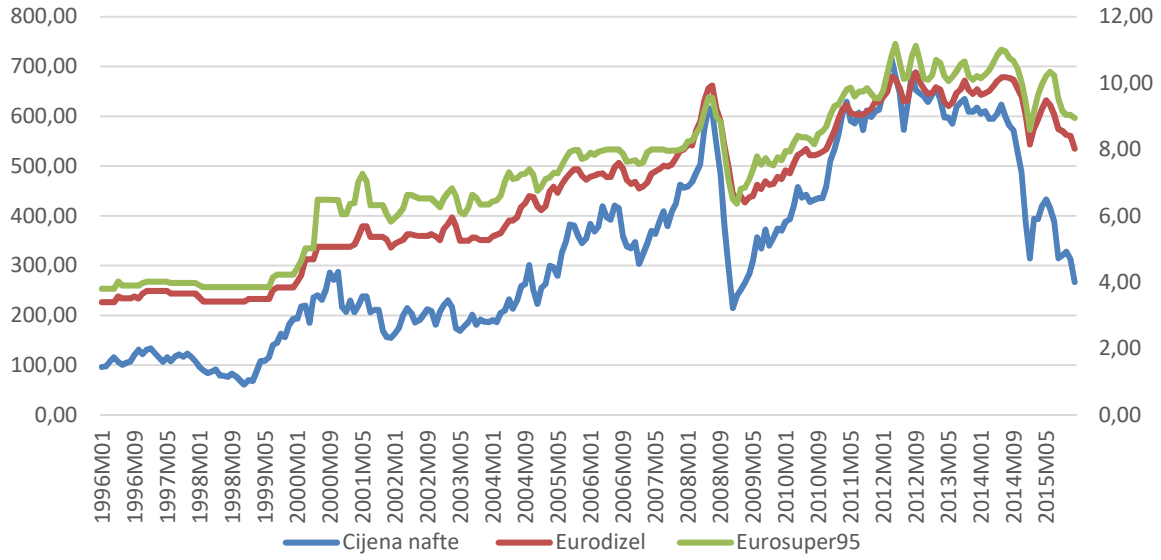

Izvor: Obrada autorice prema podacima EIA, Europe Brent Spot Price FOB (2017), HNB, Srednji tečaj HNB-a (2018)i Ministarstvo zaštite okoliša i energetike, Cijene naftnih derivata (2018)

U promatranom periodu vidljive su značajne oscilacije, kako cijena nafte (od minimalnih 61 kn/bbl do maksimalnih 716,20 kn/bbl), tako i naftnih derivata (od 3,4kn/l do 10,33 kn/l za Euro dizel, odnosno od 3,8 kn/l do 11,18 kn/l za Eurosuper95). S obzirom na fiskalnu izdašnost prihoda koju države ubiru od maloprodaje naftnih derivata, uslijed drastičnog pada cijene nafte

koncem 2014. godine punjenje državnog proračuna se smanjilo. To je većina EU članica, pa tako i Hrvatska, „korigirala“ povećanjem trošarina na naftne derivate. Ovo je razlog zbog čega vraćanjem cijena nafte na nekadašnje skromnije iznose, cijene naftnih derivata nisu doživjele ni približno jednako smanjenje krajnje cijene. Brent cijena nafte (riječ je o nominalnim vrijednostima) je tako u ožujku 2009. iznosila 265,73 kn po barelu kao i u prosincu 2015. godine (267,40 kn/bbl), ipak cijena Eurosupera95 je 2015. u prosincu bila veća čak 30% (6,85 kn/l => 8,96 kn/l), a Euro dizela 25% (6,41 kn/l => 8,03 kn/l) u odnosu na ožujak 2009. godine.

O volatilnosti cijena nafte i naftnih derivata svjedoče i podaci iz Tablice 3.6.1.1. koji pokazuju standardne devijacije Brent cijena nafte, Eurosuper95 i Euro dizela. Unutar tablice prikazane su vrijednosti standardne devijacije za period od siječnja 1996. do prosinca 2015., ali i vrijednosti triju zasebnih perioda; od 1996. do 1999., od 2000. do 2005. i od 2006. do 2015. godine. Promatrajući podatke u tablici lako se uočava rast standardne devijacije koji je sve izraženiji u novijoj povijesti čime se dokazuje rast volatilnosti, kako cijena nafte, tako i cijena naftnih derivata. Važno je istaknuti da je izračun izvršen korištenjem mjesečnih prosječnih cijena čime su već u određenoj mjeri ublaženi ekstremi kraćih vremenskih perioda.

Tablica 3.6.1.1.: Standardna devijacija cijena nafte, Eurosuper95 i Euro dizela od 1996. do 2015. godine

Standardna devijacija Period	Cijena nafte (u kn/bbl)	Eurosuper95 (u kn/l)	Euro dizel (u kn/l)
1996-1999	28,06	0,13	0,15
2000-2005	54,08	0,71	0,74
2006-2015	126,64	1,21	1,16
1996-2015	181,03	2,19	2,19

Izvor: Izračun autorice prema podacima EIA, Europe Brent Spot Price FOB (2017), HNB, Srednji tečaj HNB-a (2018) i Ministarstvo zaštite okoliša i energetike, Cijene naftnih derivata (2018)

U poglavlju koje slijedi bit će riječi o porezima i trošarinama na naftne derivate, načinu na koji oni utječu na krajnje cijene naftnih derivata, kao i njihovoj fiskalnoj izdašnosti.

3.6.2. Porezi i trošarine na naftne derivate

Kako je već ranije navedeno, maloprodajne cijene naftnih derivata sadrže i trošarine i PDV. Trošarine su posebni oblik poreza koji se na motorni benzin i dizelska goriva obračunava u fiksnom iznosu (na 1000 litara pri osnovnim uvjetima temperature energenta od +15 °C). Općenito je iznos trošarine na motorni benzin veći od onog na dizelsko gorivo.

Tablica 3.6.2.1. prikazuje kretanje trošarina na bezolovni benzin i dizelsko gorivo u periodu od 1995. do 2017., u kunama po litri.

Tablica 3.6.2.1.: Trošarine na bezolovni benzin i dizelsko gorivo u periodu od 1995. do 2017., u kunama po litri

Početak primjene	Bezolovni benzin	Dizelsko gorivo	Zakonski akt
01.07.1994.	1,60	1,40	Zakon o posebnom porezu na naftne derivate (NN 51/94)
01.07.1999.	1,80	1,60	Zakon o izmjenama i dopunama Zakona o posebnom porezu na naftne derivate (NN 67/99)
01.07.2000.	3,00	2,10	Zakon o posebnom porezu na naftne derivate (NN 55/00)
13.10.2000.	2,40	1,50	Zakon o izmjenama i dopunama Zakona o posebnom porezu na naftne derivate (NN 101/00)
01.01.2002.	1,90	1,00	Zakon o izmjeni Zakona o posebnom porezu na naftne derivate (NN 27/01)
01.05.2007.	1,65	1,00	Uredba o visini posebnog poreza na naftne derivate (NN 44/07)
01.01.2010.	2,85*	2,20*	Zakon o trošarinama (NN 83/09)
01.09.2010.	3,10	2,20	Uredba o visini trošarine za bezolovni motorni benzin (NN 102/10)
08.03.2011.	2,95	2,05	Uredba o visinama trošarina na motorne benzine i plinsko ulje (NN 28/11)
01.01.2013.	3,15	2,35	Uredba o visini trošarine na motorne benzine, plinsko ulje i kerozin za pogon (NN 137/12)
02.03.2013.	3,15	2,45	Zakon o trošarinama (NN 22/13)
23.07.2013.	3,36	2,56	Uredba o visini trošarine na motorne benzine, plinsko ulje i kerozin za pogon (NN 93/13)
03.09.2013.	3,46	2,66	Uredba o visini trošarine na motorne benzine, plinsko ulje i kerozin za pogon (NN 109/13)
17.04.2014.	3,66	2,86	Uredba o izmjeni Uredbe o visini trošarine na motorne benzine, plinsko ulje i kerozin za pogon (NN 48/2014)
17.04.2015.	3,86	3,06	Uredba o izmjeni Uredbe o visini trošarine na motorne benzine, plinsko ulje i kerozin za pogon (NN 43/2015)

*Naknade postaju dio trošarina
Izvor: Djelo doktorandice prema NN, razna godišta

Prvi značajan skok u visini trošarina vidljiv je polovinom 2000. godine, a posljedica ovog porasta trošarina vidljiva je i kod cijena derivata prikazanih Grafikonom 3.6.1.2. Nakon 2000. godine, trošarine su se postupno smanjivale sve do početka 2010. godine, kada su naglo povećane (za 72% na motorna i 120% na dizelska goriva). Razlog rasta trošarina bila je primarno harmonizacija s trošarinama u EU. Izmjenama Zakona o trošarinama (NN 83/09) Naknada za financiranje građenja i održavanja javnih cesta koja se odvojeno od iznosa trošarina naplaćivala po litri motornog benzina, odnosno dizela (0,60 kn/l za HC i 0,60 kn/l za HAC)

postala je 01.01.2010. sastavni dio trošarina tako da do stvarnog porasta davanja državi u ovom trenutku nije došlo.

Nakon blagog pada trošarina u ožujku 2011. godine, od početka 2013. godine naovamo, trošarine kontinuirano rastu. Promatrajući period od 1995. do 2015. godine, trošarine na bezolovni benzin i dizelsko gorivo povećale su se (u apsolutnom iznosu) za 140%, odnosno za 119%. Pored istaknutih iznosa trošarina na motorni benzin i dizelska goriva[147] plaćala se do 2010. godine (po litri prodanog derivata) i naknada za Hrvatske ceste (uvedena 01.04.2001.)[148] i Hrvatske autoceste (uvedena 01.01.2002.)[149].

Izmjenama Zakona o trošarinama (NN 83/2009) od siječnja 2010. godine ove su naknade postale sastavni dio trošarina. Unutar trošarina na naftne derivate kasnije je uključena naknada za poticanje proizvodnje biogoriva (uvedena 01.01.2011.)[150] kao i naknada za financiranje željezničke infrastrukture – HŽ Infrastruktura (uvedena 01.01.2014.)[151]. Pored navedenih iznosa naknada, odnosno trošarina, 2006. godine uvedena je i naknada za financiranje rada (iste godine osnovane) Hrvatske agencije za obvezne zalihe nafte i naftnih derivata – HANDA-e (uvedena 01.08.2006.). Visina naknade obračunavala se po toni naftnog derivata[152] stavljenog na domaće tržište[153], a 2013. godine (01. siječnja), kada je HANDA postala korisnik proračuna RH, naknada je ukinuta. Kretanje iznosa naknade po godinama prikazano je Tablicom 3.6.2.2.

Na tragu argumentacije o harmonizaciji trošarina s EU trošarinama, korisno je i usporediti iznose trošarina na naftne derivate (ovdje na Eurosuper95 i Euro dizel) s trošarinama u članicama EU prikazane Tablicom 3.6.2.3. Hrvatske su trošarine ispod EU prosjeka koji iznosi 559,3 eura/1000l za Eurosuper95, odnosno 449,31/1000l eura za Euro dizel.

---

[147] Jedina kategorija goriva na koju se ne plaćaju nikakve trošarine i naknade izuzev PDV-a je tzv. Plavi dizel. Plavi dizel je Euro dizel obojan plavim markerom zbog kontrole potrošnje, a služi za kao poticajna mjera (subvencija) u poljoprivredi, ribolovu, ribogojstvu i akvakulturi.
[148] Prvo u iznosu od 0,40 lp/l do konca 2001., zatim 0,60 kn/l do kraja 2013., da bi se iznos od siječnja 2014. povećao na 0,80 lp/l
[149] Prvo u iznosu od 0,60 lp/l do kraja 2013. nakon čega je iznos smanjen na 0,20 kn/l od siječnja 2014.
[150] Iznos naknade reguliran je na godišnjoj razini i kretao se u rasponu od 0,03 do 0,05 kn/l.
[151] Visina naknade iznosi 0,20 kn/l.
[152] Izvedenima iz volumena pri temperaturi +15 °C.
[153] Osnovicu za obračun naknade čine naftni derivati, neovisno o kvaliteti i komercijalnom nazivu.

Tablica 3.6.2.2.: Visina naknade za financiranje rada HANDA-e

Godina	Motorni benzin	Dizelsko gorivo	Loživa ulja
2006.	120 kn/t	120 kn/t	120 kn/t
2007.	150 kn/t	150 kn/t	150 kn/t
2008.	150 kn/t	190 kn/t	80 kn/t
2009.	200 kn/t	300 kn/t	50 kn/t
2010.	200 kn/t	300 kn/t	50 kn/t
2011.	200 kn/t	300 kn/t	50 kn/t
2012.	200 kn/t	300 kn/t	50 kn/t

Izvor: obrada autorice prema: Narodne Novine, razna izdanja i godišta

Minimalne iznose trošarina na naftne derivate, kao i krajnji rok za njihovu primjenu, definirala je svojim propisima Europska unija. EU Direktiva 2003/96/EEC[154] odredila je minimalan iznos trošarina na bezolovni motorni benzin u visini od 359 eura na 1000 litara, dok je minimalan iznos trošarina za dizelska goriva 302 odnosno 330 eura na 1000 litara s krajnjim rokom primjene početkom 2004., odnosno početkom 2010. godine.

Tablica 3.6.2.3.: Trošarine u odabranim zemljama EU, u eurima na 1000 litara u 2018.

	Eurosuper 95 (EUR/1000 l)	**Euro dizel (EUR/1000 l)**
ECC minimum	**359,00**	**330,00**
Bugarska	363,03	330,30
Hrvatska	**521,59**	**413,49**
Češka	501,09	427,33
Francuska	691,40	609,50
Njemačka	654,50	470,40
Mađarska	380,95	350,46
Italija	728,40	617,40
Nizozemska	786,39	497,81
Poljska	390,76	342,28
Portugal	659,20	471,10
Slovačka	580,17	416,05
Slovenija	546,77	468,99
Španjolska	461,28	367,30
Ujedinjeno Kraljevstvo	650,61	650,61
EU prosjek	**559,27**	**449,31**

Izvor: European Commision, Energy, Data & Analysis, Weekly Oil Bulletin, Lates duties and taxes, https://ec.europa.eu/energy/en/data-analysis/weekly-oil-bulletin (pristup: 03.08.2018.)

[154] COUNCIL DIRECTIVE 2003/96/EC, 27 October 2003, Restructuring the Community framework for the taxation of energy products and electricity

Na ovom je mjestu važno naglasiti i važnost trošarina u punjenju državnog proračuna. Trošarina na naftne derivate je prema financijskoj izdašnosti najistaknutiji predstavnik unutar skupine trošarina, kako u Hrvatskoj, tako i u većini europskih zemalja. *Cnossen (1990)* navodi sljedeće uvjete koji moraju biti zadovoljeni da bi se postigao prihodovni cilj trošarina: 1) laka administracija, 2) cjenovno neelastična potražnja za dobrima koja se oporezuju, 3) niska stopa/mogućnost supstitucije oporezovanog dobra, te 4) značajan promet/potrošnja. Naftni derivati zadovoljavaju sve navedene uvjete.

Fiskalna izdašnost trošarina na naftne derivate u Hrvatskoj vidljiva je iz podataka unutar Tablice 3.6.2.4. koji prikazuju iznose i udjele prihoda od trošarina na naftne derivate u ukupnim prihodima od trošarina kao i u ukupnim poreznim prihodima. Trošarine na naftne derivate čine više od polovine ukupnih prihoda od trošarina, pri čemu prihodi od trošarina čine gotovo petinu, a sami prihodi od trošarina na naftne derivate gotovo desetinu ukupnih poreznih prihoda.

Tablica 3.6.2.4.: Iznos i udio prihoda od trošarina na naftne derivate u ukupnim prihodima od trošarina i ukupnim poreznim prihodima od 1995., 2000., 2005., 2010. i 2015. godine (u tisućama kuna)

Godina	Prihodi od trošarina na naftne derivate (1)	Prihodi od trošarina (2)	Ukupni porezni prihodi (3)	Udio (1/2)	Udio (2/3)	Udio (1/3)
1995.	2.559	4.960	26.505	51,6%	18,7%	9,7%
2000.	4.633	7.673	39.939	60,4%	19,2%	11,6%
2005.	3.338	8.178	50.688	40,8%	16,1%	6,6%
2010.	6.933	11.972	62.857	57,9%	19,0%	11,0%
2015.	7.782	13.923	68.281	55,9%	20,4%	11,4%
Prosjek				**51,9%**	**17,9%**	**9,3%**

Izvor: Ministarstvo financija RH, Godišnjaci Ministarstva, razna godišta (http://www.mfin.hr/hr/ godisnjaci-ministarstva)
*2006. godine došlo je do naglog rasta prihoda od trošarina na naftu i naftne derivate što je posljedica uključivanja naknada za ceste (koje su prethodno bile direktan prihod Hrvatskih cesta i Hrvatskih autocesta) u državni proračun.

Iznos trošarine ulazi u poreznu osnovicu za obračun PDV-a[155], zajedno s nabavnom cijenom pojedinog derivata uvećanog za maržu. Opća stopa PDV (koja se primjenjuje i na naftne derivate) u zemljama Europske unije iznosi prosječnih 21,5% pri čemu je najniža stopa PDV-a u Luksemburgu (17%), a najviša u Mađarskoj (27%). Izuzev Mađarske i Švedske, koja ima stopu PDV 25% kao i Hrvatska, sve ostale članice EU imaju nižu opću stopu PDV-a[156].

[155] 01. siječnja 1998 PDV je po prvi puta uveden u Republici Hrvatskoj po jedinstvenoj stopi od 22%. 01. kolovoza 2009. opća stopa PDV-a povećana je na 23%, a od 1. ožujka 2012. iznosi, trenutno važećih, 25%.
[156] Stanje 01. kolovoza 2018. godine.

Na koncu, vrijedno je razmotriti i udio poreza i trošarina u krajnjoj maloprodajnoj cijeni benzina i dizela u Hrvatskoj, prikazan Grafikonom 3.6.2.1. Lijeva os grafikona pokazuje, linijama predočene, krajnje cijene Eurosuper95 i Euro dizel sa i bez poreza i trošarina, dok sive površine u pozadini predstavljaju postotni udio poreza i trošarina u maloprodajnoj cijeni u promatranom periodu od 2000. do 2015. godine.

Grafikon 3.6.2.1.: Cijene Euro dizela i Eurosuper95 u kn/l, sa i bez poreza i trošarina (lijeva os) i postotni udio poreza i trošarina u krajnjoj maloprodajnoj cijeni (desna os) od siječnja 2000. do prosinca 2015.

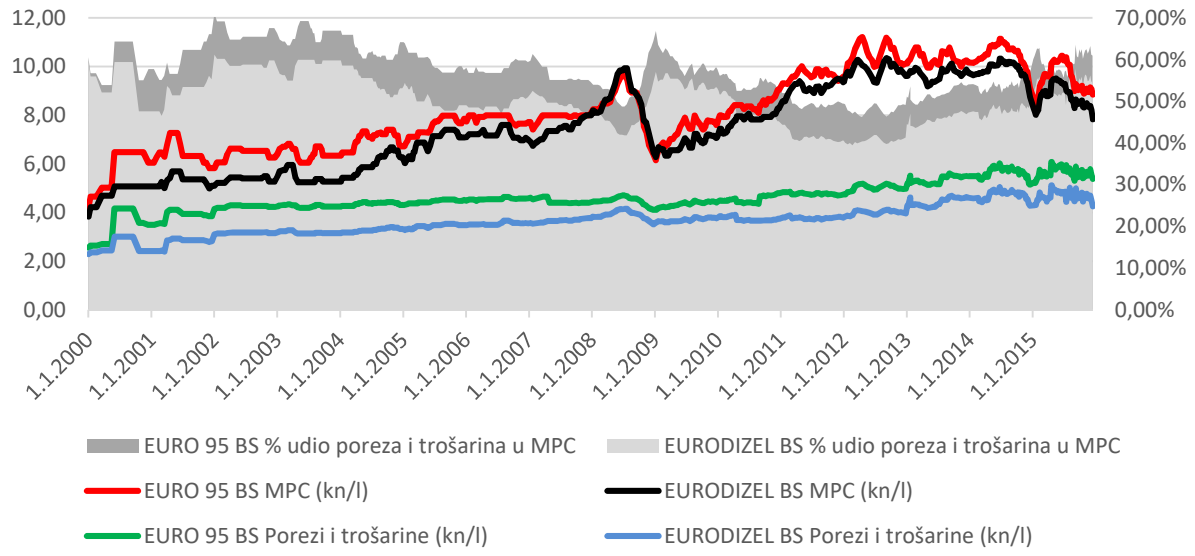

Izvor: Obrada autorice prema podacima Ministarstvo zaštite okoliša i energetike, Cijene naftnih derivata (2018)

Ono što se može zaključiti promatrajući prikazane podatke jest da je udio poreza i trošarina u krajnjoj cijeni bio viši početkom ovog perioda, kada su ujedno i cijene bile niže, odnosno; u periodima visokih cijena derivata, udio poreza se smanjuje (i obratno).

3.6.3. Međunarodna usporedba cijena naftnih derivata

Međunarodna usporedba cijena je važna kako bi se razmotrile razlike u politikama cijena među zemljama u neposrednom okruženju, posebice onima s kojima dijelimo kopnenu granicu. Upravo je u pograničnim područjima najveća „opasnost“ od odlaska domaćeg stanovništva po jeftinija goriva u susjedne zemlje. Zbog toga je važno voditi računa o kretanjima cijena naftnih derivata ne samo na domaćem tržištu već i šire, u regiji.

U Tablici 3.6.3.1. prikazane su cijene litre bezolovnog motornog benzina i dizela u eurima u Hrvatskoj i zemljama s kojima kopneno graniči; Slovenijom, Mađarskom, Srbijom, Bosnom i Hercegovinom i Crnom Gorom.

Tablica 3.6.3.1.: Cijene naftnih derivata u zemljama u regiji (u €/l) na dan 23.03.2014. i duljina kopnene granice sa susjednom zemljom

	Eurosuper95 (EUR/l)	Euro dizel (EUR/l)	Dužina kopnene granice s RH
Bosna i Hercegovina	1,220	1,200	1010,9 km
Slovenija	1,451	1,351	659,1 km
Mađarska	1,315	1,363	355,2 km
Srbija	1,309	1,330	325,8 km
Crna Gora	1,350	1,270	19,5 km
Hrvatska	1,362	1,284	
Prosjek	1,334	1,300	

Izvor: Obrada autorice prema; Vanjskotrgovinska komora BiH, Sektor za transport i telekomunikacije, http://komorabih.ba/sektor-za-transport-i-komunikacij/korisne-informacije-cijene-goriva/

Promatrajući cijene benzina, one su bile najniže u Bosni i Hercegovini (kao i cijene dizela), a najveće u Sloveniji, dok je dizel bio najskuplji u Mađarskoj. Cijena benzina u Hrvatskoj za promatrani je period blago iznad prosjeka s 1,36 eura po litri, dok je kod dizela tek nešto ispod prosjeka s 1,28 eura po litri. Kada se uzme u obzir duljina kopnene granice i cijene derivata, evidentno je da najveću prijetnju domaćoj maloprodaji naftnih derivata predstavlja maloprodajno tržište naftnih derivata Bosne i Hercegovine. I zaista, odlazak po naftne derivate preko granice nije rijedak slučaj, posebice za regiju Slavonije. Promatrajući primorsku regiju zemlje, naseljena urbana područja su ipak koncentrirana na obali pa je i udaljenost do granice s Bosnom i Hercegovinom prevelika da bi se isplatio toliki put. Navedeno vrijedi i za daleko najnaseljeniji grad Zagreb.

S obzirom na činjenicu da je od 2013. godine Hrvatska punopravna članica Europske unije, te je u skladu s tim dužna izvršiti primjenu cjelokupne pravne stečevine Unije, pa tako i direktiva koje određuju trošarine na naftne derivate (ali i tzv. strateške rezerve u sklopu politike kriznog

upravljanja u situacijama poremećaja opskrbe sirovom naftom), važno je izvršiti usporedbu cijena derivata i unutar Unije.

Tablica 3.6.3.2. prikazuje strukturu krajnje cijene bezolovnog motornog benzina i dizela u EU.

Tablica 3.6.3.2.: Struktura maloprodajne cijene naftnih derivata u EU u €/l na dan 21.03.2014

	Bezolovno gorivo (Eurosuper95)					**Dizel**				
Država	Nafta	Marža	Trošarine	PDV	*Cijena*	Nafta	Marža	Trošarine	PDV	*Cijena*
Austrija	0,465	0,190	0,482	0,228	*1,365*	0,465	0,238	0,397	0,220	*1,321*
Belgija	0,465	0,225	0,614	0,274	*1,578*	0,465	0,122	0,580	0,245	*1,413*
Bugarska	0,465	0,236	0,363	0,213	*1,277*	0,465	0,286	0,330	0,216	*1,298*
Cipar	0,465	0,297	0,429	0,226	*1,418*	0,465	0,346	0,400	0,230	*1,442*
Češka	0,465	**0,103**	0,512	0,227	*1,307*	0,465	0,193	0,437	0,230	*1,325*
Danska	0,465	0,301	0,592	**0,340**	*1,698*	0,465	0,301	0,444	0,303	*1,513*
Estonija	0,465	0,148	0,423	0,207	***1,244***	0,465	0,270	0,330	0,213	*1,279*
Finska	0,465	0,180	0,650	0,311	*1,606*	0,465	0,074	**0,679**	0,292	*1,511*
Francuska	0,465	0,161	0,607	0,247	*1,480*	0,465	0,194	0,417	0,215	*1,292*
Grčka	0,465	0,219	0,670	0,312	*1,666*	0,465	0,318	0,330	0,256	*1,370*
Hrvatska	0,465	0,200	0,424	0,272	*1,362*	0,465	0,232	0,330	0,257	*1,284*
Irska	0,465	0,195	0,588	0,287	*1,535*	0,465	0,255	0,479	0,276	*1,475*
Italija	0,465	0,257	0,728	0,319	***1,769***	0,465	**0,570**	0,337	0,302	***1,674***
Latvija	0,465	0,195	0,415	0,226	*1,301*	0,465	0,258	0,336	0,222	*1,282*
Litva	0,465	0,177	0,434	0,226	*1,303*	0,465	0,257	0,330	0,221	*1,274*
Luksemburg	0,465	0,180	0,462	**0,166**	*1,273*	0,465	0,219	0,330	**0,152**	***1,166***
Mađarska	0,465	0,138	0,432	0,280	*1,315*	0,465	0,172	0,436	0,290	*1,363*
Malta	0,465	0,266	0,489	0,220	*1,440*	0,465	0,285	0,402	0,207	*1,360*
Nizozemska	0,465	0,237	**0,747**	0,304	*1,754*	0,465	0,314	0,440	0,256	*1,475*
Njemačka	0,465	0,193	0,655	0,250	*1,563*	0,465	**0,055**	0,655	0,223	*1,399*
Poljska	0,465	0,158	0,406	0,237	*1,266*	0,465	0,130	0,444	0,239	*1,279*
Portugal	0,465	0,250	0,585	0,299	*1,600*	0,465	0,327	0,338	0,260	*1,390*
Rumunjska	0,465	0,247	**0,360**	0,257	*1,330*	0,465	0,284	**0,330**	0,259	*1,339*
Slovačka	0,465	0,179	0,550	0,239	*1,433*	0,465	0,184	0,481	0,226	*1,356*
Slovenija	0,465	0,158	0,566	0,262	*1,451*	0,465	0,161	0,481	0,244	*1,351*
Španjolska	0,465	0,258	0,425	0,241	*1,390*	0,465	0,306	0,330	0,231	*1,333*
Švedska	0,465	**0,302**	0,460	0,307	*1,534*	0,465	0,189	0,573	**0,307**	*1,534*
UK	0,465	0,147	0,674	0,257	*1,544*	0,465	0,216	0,674	0,271	*1,626*
EU prosjek	**0,465**	**0,207**	**0,527**	**0,258**	***1,457***	**0,465**	**0,241**	**0,431**	**0,245**	***1,383***
Max	**0,465**	**0,302**	**0,747**	**0,340**	***1,769***	**0,465**	**0,570**	**0,679**	**0,307**	***1,674***
Min	**0,465**	**0,103**	**0,360**	**0,166**	***1,244***	**0,465**	**0,055**	**0,330**	**0,152**	***1,166***

Izvor: Europe Energy Portal, http://www.energy.eu/fuelprices/ (preuzeto: 21.03.2014.)

U odabranom je periodu cijena barela nafte na svjetskom tržištu bila iznad 100 američkih dolara (prosječna Brent spot cijena barela nafte za ožujak 2014. iznosila je 107,48 USD) a 2014. je

ujedno i posljednja godina u kojoj su cijene barela probijale tzv. psihološku granicu od 100 USD. Cijene derivata u Hrvatskoj su bile ispod EU prosjeka i to za 6,5% kad je riječ o motornom benzinu, odnosno 7,2% kad je riječ o dizelu, pri čemu su i marže i trošarine bile ispod EU prosjeka, što se ne može reći za PDV. Iznos PDV-a u krajnjoj cijeni naftnih je derivata u Hrvatskoj viši u odnosu na EU prosjek što ni ne čudi kada se uzmu u obzir ranije spomenute razine opće stope PDV-a od 25% koju unutar EU ima samo još Švedska (osim Mađarske kod koje PDV iznosi 27%, sve ostale EU članice imaju nižu opću stopu PDV-a).

Zanimljivo je također usporediti i prosječnu cijenu goriva u SAD-u koja je u istom tjednu (17.-21.03.2014.) iznosila 3,716 USD po galonu, ili (prema tadašnjem tečaju eura prema dolaru) 0,74 eura po litri motornog benzina[157], odnosno 3,971 USD po galonu ili 0,76 eura po litri dizela[158]. Američke su cijene goriva gotovo upola niže od onih koje plaćaju građani EU-a, pa tako i hrvatski građani, što je direktna posljedica puno skromnijih davanja državi; za razliku od Europljana koji na ime poreza i trošarina izdvajaju više od polovine krajnje cijene bezolovnog motornog benzina i dizela, američki građani u istu namjenu izdvajaju manje od 20% krajnje cijene, točnije, taj je udio u kolovozu 2018. iznosio svega 17% (*EIA, 2018*).

Općenito su, promatrajući globalno, iznosi koje Europljani izdvajaju na poreze i trošarine na naftne derivate najviši. Internacionalna globalna analiza strukture krajnje cijene (*GIZ[159], 2014*) naftnih derivata, po pitanju poreza, dijeli države na četiri ključne kategorije; 1) primjena visokih subvencija (cijene derivata su niže od cijena nafte), 2) primjena subvencija (cijene nafte su između cijena nafte i cijena derivata u SAD-u), 3) primjena poreza (cijene su između cijena u SAD-u i najniže cijene derivata u EU) i 4) primjena visokih poreza (cijene iznad najniže cijene derivata u EU). Sve se EU članice nalaze u kategoriji primjene visokih poreza, dok se, izvan EU, u Bosni i Hercegovini, Kosovu, Makedoniji, Moldaviji i Ukrajini primjenjuju visoki porezi, Bjelorusija subvencionira cijene naftnih derivata, a Rusija cijene dizelskog goriva, dok na motorni benzin primjenjuje poreze (*GIZ, 2014*).

[157] EIA, Weekly U.S. Midgrade All Formulations Retail Gasoline Prices, dostupno na: https://www.eia.gov/petroleum/gasdiesel/ (pristup: 21.08.2018.)
[158] EIA, Weekly U.S. Diesel Retail Prices, dostupno na: https://www.eia.gov/petroleum/gasdiesel/ (pristup: 21.08.2018.)
[159] Njemačka razvojna agencija za međunarodnu suradnju, *njem. Deutsche Gesellschaft für Internationale Zusammenarbeit GmbH* – GIZ.

S obzirom na iznimno visoku uvoznu ovisnost o nafti/naftnim derivatima, kako Hrvatske tako i cijele Europske unije, visoke cijene naftnih derivata, koje su velikim dijelom posljedica značajnog udjela poreza i trošarina u krajnjoj cijeni, imaju za cilj destimuliranje i racionalizaciju njihove potrošnje i supstituciju ostalim oblicima energije gdje god je to moguće (poželjno onima kod kojih je uvozna ovisnost manja ili nepostojeća).

4. ISTRAŽIVANJE UTJECAJA CIJENA NAFTE NA MAKROEKONOMSKE POKAZATELJE HRVATSKOG GOSPODARSTVA

Nakon kratkog predstavljanja konceptualnog modela i formulacije empirijskih modela istraživanja, u ovom su poglavlju opisane korištene ekonometrijske metode kao i u istraživanju korištene varijable. Potom je provedena empirijska provjera postavljenih hipoteza s detaljnom elaboracijom dobivenih rezultata. Konačno, izvršena je usporedba dobivenih rezultata s postojećim teorijskim i empirijskim saznanjima iz analiziranog područja te su na koncu navedena i ograničenja provedenog istraživanja.

4.1. KONCEPTUALNI MODEL I FORMULACIJA EMPIRIJSKIH MODELA ISTRAŽIVANJA

S ciljem preglednog predstavljanja problematike istraživanja osmišljen je, a u sklopu Sheme 1. grafički prikazan, konceptualni model. Model predstavlja shemu međusobno isprepletenih utjecaja cijena nafte na odabrane makroekonomske pokazatelje temeljeno na ranije iznesenim zaključcima relevantnih znanstvenih istraživanja.

U skladu s ranije iznijetim teorijskim spoznajama, a zahvaljujući permutaciji nekoliko različitih pokazatelja cijena nafte (koji načinom kako su konstruirani inkorporiraju različite moguće načine na koje cijene nafte utječu na gospodarstvo) u ispitivanju utjecaja cijena nafte na makroekonomske pokazatelje gospodarstva, biti će ispitana prisutnost tzv. asimetrije. Potvrđivanje prisutnosti asimetrije utjecaja cijena nafte na gospodarstvo bi značilo da uslijed naftnog šoka (naglog rasta cijena nafte) dolazi do značajne negativne reakcije gospodarstva (pad BDP-a, rast nezaposlenosti, rast cijena i sl.), dok su pozitivne reakcije gospodarstva na pad cijena nafte značajno manje. Asimetrija se može očitovati kroz razlike u jačini i/ili duljini trajanja utjecaja na gospodarstvo; pri tome su negativni utjecaj rasta cijena nafte (pogotovo naftnog šoka) puno jači i dugotrajniji od pozitivnog utjecaja pada cijena nafte.

Ako se promatra rast cijena nafte kao porast troška proizvodnog inputa (energije), onda bi isti trebao rezultirati smanjenjem industrijske proizvodnje. Rast cijena nafte u tom bi smislu povećao cijene proizvodnih inputa i negativno utjecao na industrijsku proizvodnju (tim više i dulje što je mogućnost supstitucije poskupjelog energenta alternativnim energentom ili

proizvodnim inputom niža). Ako proizvođači (što najčešće i jest slučaj) prebace teret povećane cijene inputa na krajnjeg potrošača, onda dolazi i do pritiska na opću razinu cijena, odnosno na rast inflacije, a ujedno i do pada potražnje za sada poskupjelim proizvodima. Smanjenjem realnog dohotka dolazi do općeg pada potrošnje u čemu ulogu ima i troškovni udio potrošnje naftnih derivata (jer je potražnja za naftom tzv. izvedena potražnja) u ukupnoj potrošnji, kao i udio nafte/naftnih derivata u ukupnim proizvodnim/distribucijskim troškovima. Ovome nerijetko doprinosi i odgađanje kupnje trajnih potrošnih dobara, posebice automobila.

Shema 1.: *Konceptualni model utjecaja cijena nafte na makroekonomske pokazatelje gospodarstva*

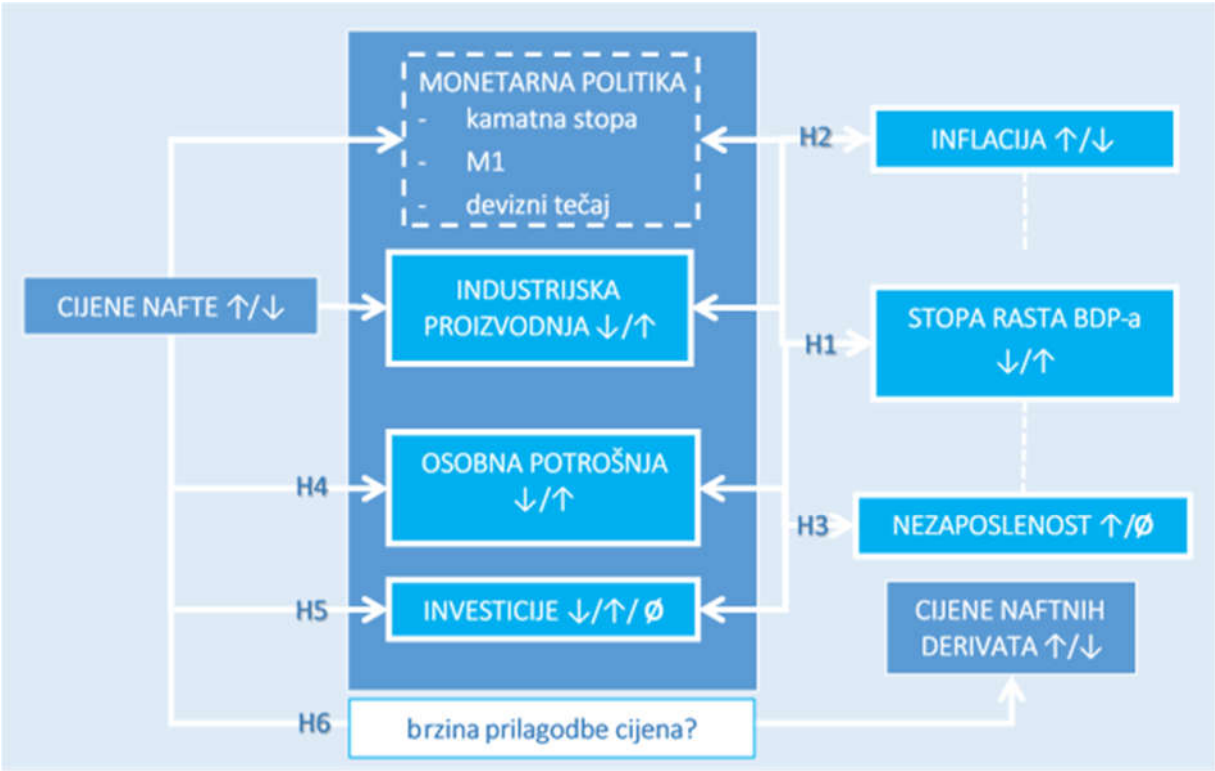

Izvor: Izrada autorice

Promatrajući investicijsku potrošnju, odnosno spremnost na poduzimanje investicija, ona opada kao posljedica rasta cijena nafte (i usporednog rasta troškova proizvodnje), posebice ako isti uslijedi nakon duljeg perioda stabilnih cijena. Investicije se u tom slučaju odgađaju ili se čak od njih i u potpunosti odustaje. Zbog navedenog, a imajući u vidu rigidnost nadnica, naftni šok može uzrokovati i rast nezaposlenosti (i potencijalnu redistribuciju proizvodnih aktivnosti u manje energetski intenzivne sektore, što može potencirati strukturnu nezaposlenost).

Inflacija koja se javlja kao posljedica rasta cijena nafte najčešće je uvozna inflacija (jer se veći dio nafte/naftnih derivata potrebnih za neometano funkcioniranje gospodarstva uvozi). Neovisno o njenom izvoru, jedan od ključnih ciljeva monetarne politike je niska i stabilna inflacija. Kako bi se spriječila visoka inflacija, suočena s rastom cijena, središnja banka primjenjuje restriktivne mjere monetarne politike koje u konačnici mogu dodatno doprinijeti smanjenju stope rasta BDP-a, čiji je rast već ugrožen prethodno iznijetim reakcijama preostalih makroekonomskih agregata.

Cilj istraživanja je ispitati utjecaj cijena nafte na makroekonomske pokazatelje u Republici Hrvatskoj pri čemu se svjetske cijene nafte promatraju kao egzogena varijabla. Kao dopuna predloženom konceptualnom modelu, a uvažavajući već naznačenu činjenicu da se nafta troši u vidu njenih derivata (odnosno da potražnja za istom proizlazi iz potražnje za naftnim derivatima), istraživanje također ispituje brzinu reakcije, odnosno prilagodbe, cijena naftnih derivata na promjene cijena nafte kao mogući izvor asimetrije.

Ukratko iznesen kompleksan međuodnos varijabli istaknutih unutar Sheme 1, prikazanog konceptualnog modela, detaljnije je opisan kroz prethodnu razradu teme disertacije, ali i u sklopu definiranja istraživačkih hipoteza, sukladno naznakama broja pomoćne hipoteze unutar prezentirane sheme. Naslanjajući se na ranije elaboracije problema i predmeta istraživanja, kao i definirane istraživačke hipoteze, u nastavku su prikazane varijable čijom će se analizom izvršiti provjera prethodno postavljenih hipoteza. Nužno je naznačiti da je prilikom testiranja hipoteza (s izuzetkom hipoteze H6) vršena permutacija četiri različita pokazatelja cijena nafte; stoga je svaki prezentirani model procijenjen četiri puta kako bi se, između ostalog, procijenilo i koji od pokazatelja ponajbolje odražava prirodu odnosa odabranih varijabli.

Prvom istraživačkom hipotezom testira se utjecaj cijena nafte na BDP, odnosno na stopu realnog rasta istog. Potrebno je istaknuti da velik broj istraživanja utjecaja cijena nafte na gospodarski rast podrazumijeva i veoma različit spektar odabranih varijabli istraživanja. Pored ovdje predloženih varijabli modela, uključuju se i varijable poput inflacije, kamatne stope, monetarnih agregata, a nerijetko i nezaposlenosti kao pokazatelja kretanja realne ekonomije (pored BDP-a), potrošnje države/proračunskog deficita, salda vanjskotrgovinske bilance, kao i na različite načine definirani pokazatelji cijena nafte. Uključivanje tih varijabli u model može pomoći poboljšanju njegove specifikacije, ali se istovremeno neizbježno smanjuju stupnjevi slobode, čime se može značajno narušiti kvaliteta i primjenjivost ekonometrijskog modela.

Slijedeći primjer *Jina (2008)* i *Aliyua (2009)*, kako bi se testirao utjecaj cijena nafte na BDP, u VAR model su uključene varijable realnog BDP-a, realnog efektivnog deviznog tečaja te pokazatelji cijene nafte. *Ito (2010)* također u svom istraživanju koristi logaritamske transformacije realnog BDP-a, realnog efektivnog deviznog tečaja, realne cijene nafte te inflacije (mjerene indeksom potrošačkih cijena). U skladu s logikom *Robala i Salvada (2008),* u model je uključena i varijabla indeksa industrijske proizvodnje kako bi se obuhvatio utjecaj cijena nafte ne samo na BDP već i na industrijsku proizvodnju. Sektor industrije bi (zbog većeg udjela energije/nafte u proizvodnom procesu), u pravilu, trebao biti osjetljiviji na promjene cijena nafte od, primjerice, uslužnog sektora. U VAR sustav jednadžbi uvrštena je i *dummy* varijabla *KRIZA*; dihotomna varijabla s vrijednošću 1 u tromjesečjima u kojima je gospodarstvo bilo u krizi, odnosno s oznakom 0 u protivnom. Iako devizni tečaj može utjecati na cijenu nafte na nacionalnoj razini, bilateralni devizni tečaj (HRK/USD) nije uključen u model, ali je zato uključena varijabla realnog efektivnog deviznog tečaja, šira definicija tečaja koja uključuje i bilateralni tečaj dolara u odnosu na hrvatsku kunu.

Općim oblikom VAR modela (prema definiciji modela (4.4.); vidjeti u odjeljku 4.2.1.1.) s ciljem empirijske provjere utjecaja cijena nafte na BDP (hipoteza H1), obuhvaćene su varijable Z_t vektora:

- ⇒ *LBDP* - prirodni logaritam realnog bruto domaćeg proizvoda,
- ⇒ *LIPI* - prirodni logaritam indeksa industrijske proizvodnje,
- ⇒ *LREER* - prirodni logaritam realnog efektivnog deviznog tečaja,
- ⇒ *LOIL* - prirodni logaritam realne cijene nafte (odnosno pripadajući pokazatelj cijene nafte[160]; *LOIL, MORK+, MORK-, SOPI, SOPD, NOPI*), te
- ⇒ *KRIZA* - dummy varijabla.

Drugom se hipotezom ispituje utjecaj cijena nafte na inflaciju. Slijedeći u odabiru varijabli primjer *Leduc i Sill (2004)* i *Coloni i Manere (2005)*, formiran je VAR model općeg oblika (4.4.), sa sljedećim varijablama Z_t vektora:

- ⇒ *LCPI* - prirodni logaritam indeksa potrošačkih cijena,

[160] Značenje kao i operacionalizacija pojedinog pokazatelja cijena nafte detaljno je prezentirano u sklopu poglavlja 4.2., pod naslovom; Pokazatelji cijena nafte

⇒ *LM1*- prirodni logaritam monetarnog agregata M1,

⇒ *IR* - kamatna stopa na prekonoćne kredite,

⇒ *LNEER* - prirodni logaritam nominalnog efektivnog deviznog tečaja,

⇒ *LIPI* - prirodni logaritam indeksa industrijske proizvodnje,

⇒ *LOILN* - prirodni logaritam cijene nafte (odnosno pripadajući pokazatelj cijene nafte; *MORK+, MORK-, SOPI, SOPD, NOPI*), te

⇒ *KRIZA* - dummy varijabla.

U pravilu, istraživanja utjecaja cijena nafte na inflaciju ispituju utjecaj cijena nafte na kamatnu stopu koja je u razvijenim gospodarstvima temeljni instrument monetarne politike. S obzirom na ranije iznijete konstatacije o kretanju inflacije u RH (vidjeti poglavlje 3.2. *Analiza kretanja inflacije*), kao i važnosti prvenstveno deviznog tečaja te transmisijskog kanala kamatne stope koji tek u posljednje vrijeme dobiva na važnosti u RH, cilj istraživanja je ustanoviti i postoji li međuovisnost između kretanja cijena nafte i kamatne stope, te posebno kretanja cijena nafte u odnosu na devizni tečaj.

Kako bi se istražio utjecaj promjena cijena nafte na nezaposlenost (treća hipoteza) konstruiran je VAR model općeg oblika (4.4.) sa sljedećim varijablama Z_t vektora:

⇒ *UNP* - stopa nezaposlenosti,

⇒ *LWAGE* - prirodni logaritam realne plaće,

⇒ *IRr* - realna kamatna stopa,

⇒ *LOIL* - prirodni logaritam realne cijene nafte (odnosno pripadajući pokazatelj cijene nafte; *MORK+, MORK-, SOPI, SOPD, NOPI*), te

⇒ *KRIZA* - dummy varijabla.

Odabir varijabli u modelu slijedi primjer istraživanja *Carruth, Hooker i Oswalda (1998), Kooros, Sussan i Semetesy (2006), Andreopoulosa (2009) te, Doğrula i Soytasa (2010).*

Sukladno naznakama u teoriji prema kojima naftni šok polučuje značajnije efekte na potražnju stanovništva i poduzeća *(Lee i Ni, 2002; Hamilton, 2008)* i na taj način stvara veći poremećaj u potražnji za konačnim proizvodom negoli prilikom njegove proizvodnje (zbog porasta cijene inputa), cilj je istražiti i na koji način promjene cijena nafte utječu na potrošnju, te konzekventno na nezaposlenost kao negativnu posljedicu pada agregatne potražnje.

Četvrtom se hipotezom ispituje utjecaj cijena nafte na osobnu potrošnju. Na temelju ranije iznesenih pretpostavki o potencijalnom utjecaju cijena nafte na potrošnju konstruiran je opći oblik VAR modela (prema formuli (4.4.)) sa sljedećim varijablama Z_t vektora:

- ⇒ *LCONS* - prirodni logaritam realne osobne potrošnje,
- ⇒ *LDI* - prirodni logaritam raspoloživog dohotka,
- ⇒ *UNP* - stopa nezaposlenosti
- ⇒ *LOIL* - prirodni logaritam realne cijene nafte (odnosno pripadajući pokazatelj cijena nafte; *MORK+, MORK-, SOPI, SOPD, NOPI*), te
- ⇒ *KRIZA* - dummy varijabla.

Slijedeći primjer *Zhanga i Broadstocka (2014),* u model je uvrštena varijabla raspoloživog dohotka (*LDI*), a jedna od varijabli koja se uvodi u model je i nezaposlenost.

S ciljem empirijske provjere pete hipoteze, o utjecaju cijena nafte na investicije, formiran je VAR model (prema jednadžbi (4.4.)) sa definiranim varijablama Z_t vektora:

- ⇒ *LINV* - prirodni logaritam realnih investicija,
- ⇒ *LBDP* - prirodni logaritam realnog bruto domaćeg proizvoda,
- ⇒ *IRr* - realna kamatna stopa,
- ⇒ *LOIL* - prirodni logaritam realne cijene nafte (odnosno pripadajući pokazatelj cijena nafte; *MORK+, MORK-, SOPI, SOPD, NOPI*), te
- ⇒ *KRIZA* - dummy varijabla,

slijedeći uobičajenu ekonomsku logiku koja nalaže da su investicije pozitivna funkcija prodaje, odnosno BDP-a, i negativna funkcija kamatne stope *(cf. Blanchard, 2005, str. 88.).*

Konačno, kako bi se ispitao odnos cijena nafte i cijena naftnih derivata (hipoteza H6), Korišteni su modeli korekcije pogreške kako bi se ustanovio dugoročan, a potom i kratkoročan odnos cijene nafte i cijena naftnih derivata, a potom i ispitalo eventualno postojanje asimetrije u prilagodbi cijena naftnih derivata cijeni nafte. Dugoročan odnos cijene nafte i cijena naftnih derivata u RH ispitat će se modelom korekcije pogreške predloženim od strane *Liu et al. (2010):*

$$LFUEL_t = \alpha_0 + \alpha_1 LOIL_t + \varepsilon_t \qquad (4.1.)$$

gdje je:

⇒ *LFUEL* - prirodni logaritam cijene naftnih derivata; (prosječna mjesečna) maloprodajna cijena goriva bez poreza i trošarina; dizel (*LDIESEL)* i bezolovni motorni benzin *(LES95)* u kn/l

⇒ *LOIL* - prirodni logaritam cijene nafte (denominirane u kn/l),

⇒ α_0 - konstantni član (ovdje dio cijene naftnih derivata koji ne ovisi o cijenama nafte),

⇒ α_1 - stupanj prilagodbe cijena naftnih derivata cijenama nafte u dugom roku i

⇒ ε_t - greška.

Kratkoročna dinamika cijena naftnih derivata u odnosu na cijenu nafte ispitat će se modelom korekcije pogreške (*engl. Error Correction Model - ECM*) *(Engle i Granger, 1987).* U tu se svrhu rezidualna odstupanja (ε_t) prethodno procijenjene jednadžbe (4.1.) uključuju se u model kao dodatni član korekcije pogreške ($\hat{\varepsilon}_{t-1} = LFUEL_{t-1} - \alpha_0 - \alpha_1 LOIL_{t-1}$). Korištenjem modela korekcije greške mogu se istražiti razlike u cijenama naftnih derivata kada su one ispod ili iznad ravnotežne razine. Također je moguće ispitati koliko je dugo potrebno cijenama derivata da se u potpunosti prilagode promjenama cijena nafte računajući tzv. Mean Adjustment Lag (MAL), odnosno pomak potreban za prilagodbu srednjoj vrijednosti. Model je u standardnom obliku sljedeći:

$$\Delta LFUEL_t = \beta_1 \Delta LOIL_t + \beta_2 (LFUEL_{t-1} - a_0 - a_1 LOIL_{t-1}) + v_t \qquad (4.2.)$$

gdje je:

⇒ β_1 - kratkoročna stopa prilagodbe cijena naftnih derivata cijeni nafte (pokazuje koliko se promjena cijene nafte reflektira na promjene cijena naftnih derivata),

⇒ β_2 - brzina prilagodbe pri odstupanju od ravnotežne vrijednosti,

⇒ $\hat{\varepsilon}_{t-1} = LFUEL_{t-1} - \alpha_0 - \alpha_1 LOIL_{t-1}$ - rezidual, odstupanje od srednje vrijednosti u vremenu *t-1* i

⇒ v_t - proces inovacija.

Kako bi se uvažila mogućnost asimetrične prilagodbe cijena naftnih derivata kad odstupaju od srednje/ravnotežne vrijednosti (bilo pozitivno ili negativno) uvodi se pokazatelj λ . Pokazatelj

λ je jednak 1 ako je rezidual ($\hat{\varepsilon}_{t-1} = LFUEL_{t-1} - \alpha_0 - \alpha_1 LOIL_{t-1}$) pozitivan, i 0 u protivnom. Asimetrična kratkoročna dinamička relacija predstavljena je jednadžbom:

$$\Delta LFUEL_t = \delta_1 \Delta LOIL_t + \delta_2 \lambda \hat{\varepsilon}_{t-1} + \delta_3 (1-\lambda) \hat{\varepsilon}_{t-1} + \eta_t \qquad (4.3.)$$

gdje je:

- ⇒ δ_1 - ekvivalent β_1 u prethodnom modelu; kratkoročna stopa prilagodbe cijena naftnih derivata cijeni nafte (pokazuje koliko se promjena cijene nafte reflektira na promjene cijena naftnih derivata),
- ⇒ δ_2 - brzina prilagodbe ravnotežnoj vrijednosti kad je vrijednost iznad ravnotežne,
- ⇒ δ_3 - brzina prilagodbe ravnotežnoj vrijednosti kad je vrijednost ispod ravnotežne.

U konačnici se provjera postojanja cjenovne asimetrije svodi na provjeru postojanja statistički značajne razlike između vrijednosti parametara δ_2 i δ_3.

4.2. METODOLOGIJA EMPIRIJSKOG ISTRAŽIVANJA

Opis metodologije empirijskog istraživanja, sukladno najavi u uvodnom dijelu disertacije, obuhvaća definiranje korištenih statističko-ekonometrijskih metoda, kao i pojašnjenje procedura čija je provedba nužna kako bi se primijenile korištene statističko-ekonometrijske metode. U drugom je dijelu ovog potpoglavlja dana detaljna elaboracija korištenih pokazatelja, kao i njihova operacionalizacija. Ekonometrijska analiza će se izvršiti uz podršku računalnog programa EViews 8.

4.2.1. Opis korištenih statističko-ekonometrijskih metoda

Standardno se u literaturi prilikom istraživanja utjecaja cijena nafte na makroekonomske pokazatelje koriste VAR modeli i VECM modeli (*cf. Hamilton, 1983; Jimenez-Rodrıguez i Sanchez, 2005; Kilian, 2009; Blanchard i Galı, 2010; Mandal et al., 2012 i dr.*), odnosno modeli korekcije pogreški u bivarijantnom okruženju (kod provjere hipoteze H6, *cf. Liu et al., 2010*).

4.2.1.1. Vektorski autoregresijski modeli i vektorski modeli korekcije pogreški

U istraživanju je, sukladno praksi kod ovakvog tipa istraživanja, korišten VAR model. U praksi se VAR model, koji je po prirodi dinamički model, primjenjuje prilikom analize međusobne ovisnosti makroekonomskih varijabli. VAR model predstavlja ključan alat moderne ekonometrije sa dvama osnovnim primjenama; u formalnom testiranju ekonomskih teorija koje pretpostavljaju „određene“ oblike povezanosti ekonomskih varijabli, te u analizi dinamike pojava u prethodnim periodima (*Bahovec i Erjavec, 2009, str. 339*). VAR modeli služe kako bi se istražila međusobna povezanost između dviju ili više varijabli. U kontekstu ovog istraživanja istražuje se povezanost između cijena nafte i odabranih makroekonomskih pokazatelja u Republici Hrvatskoj. U analizi VAR modela uobičajeno se koriste tri alata (*Maddala, 2001, str. 394-395; Gujarati, 2003, str. 565-713*), Grangerov test uzročnosti te alati tzv. inovacijske analize: funkcija impulsnog odgovora (*IRF, engl. Impulse Response Function*) i analiza ortogonalne dekompozicije varijanci prognostičkih pogrešaka (*VD, engl. Variance Decomposition*).

Kod VAR modela konstruira se sustav dinamičkih linearnih jednadžbi na način da je vektor endogenih varijabli prikazan u ovisnosti o prošlim vrijednostima (*engl. lagged values*) svih varijabli u sustavu. U analizi je korišten Simsov (*Sims, 1980*) VAR model koji ne postavlja ograničenja na parametre modela, odnosno nema podjele na endogene i egzogene varijable. U tome se ogleda njegova prednost (*Gujarati, 2003, str. 701*). Ipak, prilikom konstruiranja VAR modela koristi se ekonomska teorija, prije svega u determiniranju varijabli koje pokazuju dinamički međuodnos.

Opći oblik vektorskog autoregresijskog modela na temelju *n* varijabli s duljinom pomaka *k* je (*Bahovec i Erjavec, 2009, str. 339*):

$$Z_t = \mu + A_1 Z_{t-1} + \ldots + A_k Z_{t-k} + \psi D_t + e_t \tag{4.4.}$$

gdje je:

- ⇒ Z_t *n*-dimenzionalni vektor potencijalno endogenih varijabli reda (*n* x 1),
- ⇒ $A_1,\ldots,A_k$ su kvadratne matrice autoregresijskih parametara reda (*n* x *n*),
- ⇒ D_t je vektor nestohastičkih egzogenih varijabli s matricom parametara Ψ,
- ⇒ μ je vektor konstantnih članova za svaku varijablu,

⇒ e_t je vektor inovacija, tj. n-dimenzionalni vektorski proces bijelog šuma s očekivanom vrijednosti nula i matricom kovarijanci Σ.

Vektor D_t može sadržavati trende komponentu, binarne (dummy) varijable kako bi se u model uključio utjecaj različitih intervencija (vanjskih šokova) ili na primjer može sadržavati neke sezonske komponente ako je u varijablama prisutan utjecaj sezone (*Bahovec i Erjavec, 2009, str. 340*).

Važan kriterij prilikom odabira primjerene metodologije je i priroda podataka koji se koriste. U kojem obliku varijabla i njeni podaci ulaze u model ovisi o tome sadrži li vremenski niz jedinični korijen, odnosno jesu li korišteni vremenski nizovi stacionarni ili nestacionarni. Ako su analizirane varijable stacionarne, odnosno ne sadrže jedinični korijen, VAR model se može procijeniti korištenjem podataka/varijabli u razinama. Ako su jedna ili više varijabli nestacionarne (sadrže jedinični korijen), može se pojaviti tzv. lažna/prividna regresija (*engl. spurious regression*, *Granger i Newbold, 1974*). Kako bi se navedena prepreka izbjegla, nužno je otklanjanje jediničnog korijena iz korištenih vremenskih nizova, a isto se najčešće provodi diferenciranjem podataka. Ako se, s druge strane, pokaže da postoji dugoročan odnos između varijabli, odnosno, ako razlika između para varijabli postaje stacionarna kako se varijable usporedno kreću kroz vrijeme, tada među varijablama postoji kointegracija. U navedenom se slučaju sugerira korištenje VECM modela (*Engle i Granger, 1987*)[161].

S ciljem analize dugoročne ravnoteže, VAR modele je potrebno upotpuniti informacijama o dugoročnoj ravnoteži budući da isti zanemaruju te informacije koje pruža ekonomska teorija (*Kennedy, 2003*). Iz tog razloga definiran je model koji ima opći oblik VAR modela, a dodane su mu egzogene varijable - vektorski model korekcije pogreške (*VECM*). VECM objedinjuje kratkoročnu i dugoročnu dinamiku pojava. Riječ je o tipu modela koji procjenjuje brzinu kojom se zavisna varijabla vraća u ravnotežu nakon promjene nezavisne varijable. Kako VECM model nudi korisnu procjenu kratkoročnih i dugoročnih učinaka jedne varijable u odnosu na drugu,

[161] Oprečno navedenom, nekolicina autora kod ovakvog tipa istraživanja (u području ekonomike energetike) preferiraju procjenu VAR modela korištenjem vremenskih nizova u razinama (za detaljniju elaboraciju *cf. Farzanegan i Markwardt, 2008*). Općenito se u ekonometrijskim krugovima vode rasprave o opravdanosti logaritmiranja i diferenciranja izvornih vrijednosti vremenskih nizova čime se, kako navode pobornici korištenja originalnih vremenskih nizova, gubi dio vrijednih informacija o samim pojavama. Ipak ovdje se, slijedeći primjerice *Ferderera (1996)* ali i opću ekonometrijsku praksu, procjenjuju modeli sa stacionarnim vremenskim nizovima (dakle iste se po potrebi logaritmira i diferencira).

često se koristi u istraživanjima ekonomskih pojava. Korištenje modela korekcije grešaka popularizirali su inicijalno *Engel i Granger (1987).*

VECM model dan je izrazom:

$$\Delta Z_t = \sum_{i=1}^{k-1} \Gamma_i \Delta Z_{t-i} + \Pi Z_{t-k} + e_t, \tag{4.5.}$$

gdje je ΔZ_t vektor prvih diferencija *n* varijabli, $\Gamma_i = A_i + A_{i-1} + ... + A_1 - I$, pri čemu je *I* jedinična matrica reda *n*, $\Pi = \Gamma_k = A_k + A_{k-1} + ... + A_1 - I$. U modelu se procjenom parametara matrica $\hat{\Gamma}_i$ i $\hat{\Pi}$ povezuje kratkoročna dinamika (član $\sum_{i=1}^{k-1} \Gamma_i \Delta Z_{t-i}$) i dugoročna dinamika (član ΠZ_{t-k}) pojava (*Bahovec i Erjavec, 2009, str. 370*). Najveća prednost modela je jednostavnost u smislu da ga je lako primijeniti u ekonomskim istraživanjima koja pretpostavljaju dugoročnu ravnotežu (odnos) između varijabli.

U sklopu provjere svih hipoteza nastojalo se pomiriti dvije krajnosti uvažavajući kriterij parsimonije; s jedne strane obuhvatiti što veći broj objasnidbenih varijabli, a s druge strane ograničiti broj istih kako se ne bi narušila kvaliteta procijenjenih parametara imajući u vidu duljinu, točnije kratkoću, raspoloživih vremenskih nizova (posebno kada je riječ o modelima koji uključuju tromjesečne vremenske nizove). Imajući navedeno u vidu, u modelima je preferiran multivarijantni okvir (spram bivarijantnog) kako ne bi došlo do ispuštanja (izostavljanja) važnih makroekonomskih varijabli. Pored navedenog, multivarijanti okvir pomaže u istraživanju transmisijskih mehanizama unutar gospodarstva jer omogućuje eventualnu detekciju efekata koji ne moraju nužno biti direktni. Primjerice, cijene nafte mogu, ali i ne moraju, direktno utjecati na realni BDP; moguće je da je njihov utjecaj na BDP, ako se i dokaže, indirektan (preko ostalih varijabli u modelu).

Sezonske varijacije vremenskog niza značajno utječu na njegovu ukupnu varijancu, stoga prognoze koje zanemaruju važnost sezonske komponente imaju veliku varijancu (prognostičku pogrešku). Zato je potrebno, u slučaju sezonskih varijacija pojave, empirijsku analizu provoditi nad desezoniranim (vremenski prilagođenim) podacima. Vremenski nizovi korišteni u ovom istraživanju su desezonirani TRAMO/SEATS metodom koja je među najvažnijim sustavima

desezoniranja[162] o čemu svjedoči i njena zastupljenost u obradi podataka na razini Eurostata i DZS-a, kao i ostalih europskih statističkih ureda (*DZS, ESS Smjernice o desezoniranju, 2011*).

U pojedinim slučajevima koriste se logaritamske vrijednosti promatranog vremenskog niza jer ovakva transformacija stabilizira varijancu vremenskog niza, odnosno ublažava utjecaj netipičnih vrijednosti unutar vremenskog niza. To potencira veću preciznost rezultata daljnje ekonometrijske analize (*Lütkepohl i Xu, 2009*). Pored navedenog, uvođenjem logaritamskih vrijednosti omogućuje se analiza pomoću postotnih promjena, odnosno pokazuje se utjecaj promjene jedne varijable na drugu varijablu u postotcima.

Važan korak u primjeni VAR metodologije je i odabir duljine (vremenskog) odmaka „k“ zbog osjetljivosti empirijske analize na izbor iste. Ideja je da se napravi kompromis između poboljšanja dijagnostike modela (što zahtijeva veći broj odmaka) i osiguravanja dovoljnog broja stupnjeva slobode (što zahtijeva parsimonijsku parametrizaciju modela, tj. izbor manjeg broja pomaka) (*Bahovec i Erjavec, 2009, str. 344.*). Kako bi odabir optimalne duljine odmaka bio što primjereniji, u analizi je korišteno nekoliko postupaka odabira duljine odmaka. Pored navedenog, u donošenju odluke o optimalnoj duljini vremenskog odmaka uzeti su u obzir i rezultati analize dijagnostike modela na način da se odabire model koji pokazuje superiornija svojstva u smislu provedene dijagnostike. Navedeno se odnosi na analizu stabilnosti modela kao i testiranje autokorelacije, heteroskedastičnosti i normalnosti reziduala.

Kako bi se procijenila važnost pojedine varijable u sustavu ili pak njena statistička značajnost, uslijed izvršene modelske procjene korišteni su Wald testovi kako bi se ispitala (kroz empirijsku analizi elaborirane pomoćne hipoteze) ograničenja na procijenjene parametre. Wald test u tom smislu testira hipotezu da su odabrani procijenjeni parametri jednaki nuli ili, alternativno nekoj definiranoj vrijednosti (*Fahrmeir et al., 2013; Ward i Ahlquist, 2018).* Što je veća razlika između zadane vrijednosti ograničenja i empirijske vrijednosti procijenjenog parametra time je i veća vjerojatnost da je procijenjeni parametar statistički značajan. Rezultati Wald testa generirani su iz programskog paketa Eviews 8.

[162] Cjeloviti opis TRAMO/SEATS sustava dan je u *Gomez (2000).*

4.2.1.2. Ispitivanje stohastičkih svojstava vremenskih nizova

Sljedeći korak u procjeni VAR modela (utjecaja cijena nafte na odabrane makroekonomske pokazatelje) zahtijeva ispitivanje stohastičkih svojstava vremenskih nizova, ispitivanje reda integriranosti. VAR model zahtijeva korištenje stacionarnih vremenskih nizova koji imaju konstantno očekivanje, konstantu i konačnu varijancu. Vremenski je niz, jednostavnije rečeno, stacionaran ako je njegova aritmetička sredina neovisna o vremenu te se njegova varijanca ne mijenja sustavno kroz vrijeme (*Gujarati, 2003, str. 26*). Ako analizirani vremenski niz podataka nije stacionaran (posjeduje jedinični korijen), daljnja analiza na temelju takvog niza može utjecati na točnost procijenjenih parametara, a rezultati analize mogu stvoriti privid utjecaja zavisne varijable na nezavisnu (*engl. spurious regression*). Zbog navedenog je iznimno važno ispitati stacionarnost korištenih vremenskih nizova (*Phillips, 1986*).

Razlika između vremenskih nizova sa (nestacionarnih) i bez jediničnog korijena (stacionarnih) ima i jasnu ekonomsku implikaciju: dok utjecaj slučajnih šokova na razinu stacionarnog vremenskog niza slabi tijekom vremena, efekt šoka na razinu nestacionarnog vremenskog niza (koji ima jedinični korijen) je permanentan[163]. Pored navedenog moguća je i pojava kointegracije među varijablama, no ista se teorijski javlja samo kada su sve varijable u modelu istog reda integracije.

Općenito, ako vremenski niz ima *d* jediničnih korijena, onda je isti integriran reda *d* i potrebno ga je diferencirati *d* puta kako bi se osigurala njegova stacionarna reprezentacija (I(*d*)). Ako se pokaže da je odabrani vremenski niz u originalnim vrijednostima podataka stacionaran, tada je on nultog reda integriranosti (ili I(0)). Ako se pokaže da odabrani vremenski niz nije stacionaran, isti se diferencira dok se ne postigne stacionarnost („odstrani“ jedinični korijen). U praksi se stacionarnost najčešće postigne već prvom (eventualno drugom) diferencijom pa se za takve nizove kaže da su integrirani reda jedan (ili I(1)) (*Bahovec i Erjavec, 2009, str. 206-261*).

[163] Ova je razlika posebno važna kod ispitivanja poslovnih ciklusa jer će odstupanje BDP-a od dugoročnog trenda biti privremeno, kako nalaže ekonomska teorija, a ne permanentno, kako bi bilo kad se koristi vremenski niz BDP-a koji sadrži jedinični korijen. Prisutnost jediničnog korijena u vremenskom nizu BDP-a sugerira da negativni šokovi iz recesijskih perioda trajno reduciraju razinu BDP-a, što nije točno (značilo bi da se BDP ne može oporaviti nakon recesije) stoga je izrazito važno ekonometrijskim postupcima „odstraniti“ jedinične korijene iz originalnih vremenskih nizova.

Stacionarnost vremenskih nizova (odnosno red integriranosti) ispitana je uz pomoć standardnih testova jediničnog korijena (*engl. Unit root test*); tzv. proširenog (*engl. Augmented*) Dickey-Fuller - ADF testa *(Dickey i Fuller, 1979)*, Phillips-Peron – PP testa (*Philips i Perron, 1988*) i Kwiatkowski, Phillips, Schmidt i Shin - KPSS testa (*Kwiatkowski et al., 1992*). U slučaju postojanja strukturnih lomova u vremenskim nizovima ADF može postati pristran i voditi krivim zaključcima. Zbog toga se uz navedeni test koriste i PP i KPSS test. PP test se smatra superiornim kod analize agregiranih podataka, iako je manje pouzdan od ADF testa u slučajevima kada postoji velik broj negativnih autokorelacija diferenciranih vrijednosti niza. Kritične razine ADF i PP testa identične su i jednako se interpretiraju. Prvo se analiziraju varijable u razinama i ako niz nije stacionaran, isti se diferencira nakon čega se ponovno ispituje stacionarnost. Nadalje, ako niz prvih diferencija nije stacionaran, postupak se ponavlja, dok se niz ne diferencira dovoljno puta kako bi postao stacionaran (*Bahovec* i *Erjavec, 2009, str. 362-363*).

Kod prethodno navedenih testova hipoteze su postavljene na sljedeći način:

ADF:

H_0 ... Y_t *(niz) je nestacionaran proces*

H_1 ... Y_t *(niz) je stacionaran proces*

PP:

H_0 ... Y_t *(niz) je diferencijalno stacionaran proces*

H_1 ... Y_t *(niz) je trend stacionaran proces.*

KPSS:

H_0 ... Y_t *(niz) je stacionaran proces*

H_1 ... Y_t *(niz) je nestacionaran proces*.

Nultom hipotezom ADF i PP testa pretpostavlja se postojanje jediničnog korijena, a kod KPSS testa njegovo nepostojanje, stoga je cilj testa identificirati vremenski niz koji ne sadrži jedinični korijen (te je, stoga, stacionaran), odnosno, odbaciti nultu hipotezu za ADF i PP test, a alternativnu za KPSS. Nulta se hipoteza odbacuje ako su pripadajući empirijski t-omjeri veći od kritičnih granica testa. Standardni se testovi procjenjuju na temelju regresijske jednadžbe koju je moguće proširiti dodavanjem konstante i/ili trenda. Ovdje su u svrhu istraživanja korištena tri modaliteta regresijske jednadžbe na temelju koje se testira prisutnost jediničnog korijena, a to su: sa konstantom i trendom, sa konstantom, te bez konstante.

Snaga i statistička značajnost testova jediničnog korijena ponekad je „mala” zbog čega se često zaključuje da je varijabla nestacionarna, iako se u stvarnosti radi o stacionarnoj varijabli (H_0 se odbacuje rjeđe nego što bi trebalo). Kako bi se doskočilo ovom problemu, prilikom testiranja KPSS testom statističke hipoteze se ne tretiraju jednako, odnosno nulta je hipoteza „važnija“ od alternativne. Kod donošenja odluke temeljem provedenih testova zato se češće i koristi signifikantnost $\alpha = 1\%$ i $\alpha = 5\%$. Kombinacijom gornjih testova moguća su četiri različita zaključka:

- ⇒ odbacivanjem H_0 sa ADF i PP testovima i neodbacivanjem sa KPSS testom dokazuje se stacionaranost analiziranih podataka;
- ⇒ neodbacivanje H_0 sa ADF i PP testovima i odbacivanje sa KPSS testom čvrsto indicira da je niz I(1);
- ⇒ neodbacivanje H_0 sa svim testovima ukazuje da podaci nisu dovoljno reprezentativni, odnosno da vremenski nizovi podataka nisu dovoljno dugi;
- ⇒ odbacivanje H_0 sa svim testovima indicira da vremenski nizovi podataka nisu ni I(1) ni I(0).

Kada rezultati testova jediničnog korijena ukazuju na postojanje jediničnog korijena, vremenskom nizu se računaju prve diferencije te se test ponavlja. Procedura diferenciranja se zaustavlja kada se otkloni jedinični korijen iz vremenskog niza.

Kada varijable imaju jedinične korijene (nisu stacionarne), potrebno je testirati je li niz reziduala početnog modela (ne)stacionaran, te jesu li varijable u modelu kointegrirane. Ako korišteni vremenski nizovi nemaju isti red integracije, točnije ako nisu stacionarni u razinama, uobičajeno je u sljedećem koraku procijeniti eventualno postojanje kointegracije te, ako se ista pokaže, model procijeniti VECM, a ne VAR modelom. Smatra se, naime, da je u tom slučaju VECM model superioran jer kointegracijski vektori prikazuju dugoročno ponašanje varijabli, te se stoga smatra da VECM model producira bolje rezultate inovacijske analize koja preciznije reflektira vezu među varijablama od VAR modela. Međutim, osnovna pretpostavka kointegracije nalaže da varijable moraju biti integrirane istog reda. Istraživanja *Naka i Tufte (1997), Engle i Yoo (1987), Clemens i Hendry (1995), Lin i Tsay (1996)* i *Hoffman i Rasche (1996)* pokazuju kako je VAR bez *a priori* ograničenja superioran u odnosu na VECM u kratkom roku. Pored navedenog, valja istaknuti kako su *Naka i Tufte (1997)* proučavali performanse inovacijske analize VECM i VAR modela te zaključili kako su rezultati kod kratkog roka gotovo identični. Sve navedeno sugerira VAR metodologiju kao optimalan izbor

u izvođenju ekonometrijske procjene utjecaja cijena nafte na odabrane makroekonomske pokazatelje u RH.

4.2.1.3. Johansenova procedura i ispitivanje kointegracije

Engle i Granger (1987) ističu kako linearna kombinacija dvaju ili više nestacionarnih varijabli može biti stacionarna čak i ako pojedinačno one to nisu. Kao posljedica, promatrani su vremenski nizovi kointegrirani jer postoji stacionarna linearna kombinacija nestacionarnih vremenskih nizova, pri čemu promatrani vremenski nizovi čine kointegracijski vektor. Točnije, kointegracija se javlja ako razlika između para varijabli postaje stacionarna kako se varijable usporedno kreću kroz vrijeme. U tom slučaju ocjene parametara metodom najmanjih kvadrata u modelu nisu pouzdane, te je potrebno ocijeniti parametre u jednadžbi originalnih varijabli. Također, ako su varijable kointegrirane, testovi stacionarnosti vremenskih nizova mogu biti nepouzdani.

Općenito, ako su vremenski nizovi različitog stupnja integriranosti linearno kombinirani, njihova će kombinacija polučiti red integriranosti jednak najvišem redu integriranosti među ponuđenim (integriranim) vremenskim nizovima *(Brooks, 2008, str. 335).* U istraživanju je korištena Johansenova procedura *(Johansen, 1988; Johansen i Juselius, 1990; Johansen, 1995),* odnosno Johansenov test kointegracije baziran na VAR metodologiji. Valja imati na umu da su u ekonometrijskom smislu vremenski nizovi razmjerno kratki, što je često jedan od najvećih prigovora upotrebi ove metode na vremenskim nizovima zemalja u tranziciji. Ipak, bez obzira na navedeni nedostatak, ova se metoda često koristi za razne analize tranzicijskih zemalja (*Vizek, 2006*). Da bi se utvrdilo jesu li kombinacije vremenskih nizova u Johansenovoj proceduri kointegrirane, koriste se λ_{trace} i λ_{max} test statistike kojima se utvrđuje broj kointegracijskih vektora (odnosa) među varijablama.

Kointegrirane varijable su nestacionarne varijable između kojih postoji dugoročna ravnoteža. Navedeno svojstvo matematički se može prikazati na sljedeći način. Neka su pojave X_t i Y_t nestacionarne i neka je Y_t linearna funkcija od X_t, tj. Y_t se može prikazati kao:

$$Y_t = \alpha + \beta X_t + \varepsilon_t . \qquad (4.6.)$$

Ako je pretpostavka točna, odstupanja između Y_t i linearne funkcije $(\alpha + \beta X_t)$

$$\varepsilon_t = Y_t - (\alpha + \beta X_t) \tag{4.7.}$$

trebala bi činiti stacionaran proces, tj. razlika između dinamika pojava X_t i Y_t morala bi biti ograničena. U tom slučaju, pojave X_t i Y_t imati će sličnu dugoročnu dinamiku. Za pojave koje zadovoljavaju navedeno svojstvo kaže se da su kointegrirane reda (1,1) i zapisuje se CI(1,1). Uvjet za postojanje kointegracije je da obje pojave sadrže trend, tj. da su integrirane s istim redom integracije (*Bahovec i Erjavec, 2009, str. 327*). Na temelju analize integriranosti i kointegriranosti varijabli može se definirati odgovarajući VAR ili VECM model. Prema Johansenovoj proceduri potrebno je odrediti rang matrice Π iz jednadžbe (4.5). Prema tome, ako je rang matrice Π jednak broju varijabli u modelu, vektorski proces Z_t je stacionaran. U slučaju ako je rang matrice Π = *r*, pri čemu je *r* manji od broja varijabli u modelu Z_t je nestacionaran vektor i postoji *r* kointegracijskih relacija. Tada se matrica Π može rastaviti na:

$$\Pi = \alpha\beta' \tag{4.8.}$$

gdje su α i β matrice reda *n x r*. Matrica β naziva se kointegracijska matrica čiji stupci sadrže parametre pripadnih jednadžbi dugog roka. Matrica α je matrica brzina korekcije pogreške, čiji se elementi interpretiraju kao brzine prilagođavanja varijabli ravnotežnom stanju. Ako je matrica Π nul-matrica ili regularna matrica čiji je rang jednak broju varijabli *n*, tada ne postoji kointegracija među varijablama. Kada je matrica Π singularna matrica čiji je rang *r* manji od broja varijabli *n*, postoji *r* kointegracijskih relacija između varijabli.

Za određivanje broja kointegracijskih vektora koriste se dva testa: test traga matrice svojstvenih vrijednosti (λ_{trace}) i test najveće svojstvene vrijednosti (λ_{max}). Distribucija test veličina, a time i kritične vrijednosti λ_{trace} i λ_{max} testova, ovise o specifikaciji determinističkih komponenti u VEC modelu (*Bahovec i Erjavec, 2009, str. 376-378*).

Hipoteze testa traga matrice svojstvenih vrijednosti su sljedeće:

$$H_0: \quad \lambda_{r+1} = \lambda_{r+2} = \ldots = \lambda_n = 0 \quad \text{..... broj kointegracijskih relacija} \leq r \tag{4.9.}$$

$$H_1: \quad \lambda_{r+1} \neq 0 \quad \text{..... broj kointegracijskih relacija} \neq r$$

Hipoteze testa najveće svojstvene vrijednosti su sljedeće:

H_0: *broj kointegracijskih relacija = r* (4.10.)

H_1: *broj kointegracijskih relacija = r+1*

Kod oba navedena testa testiranje se provodi sve dok se prvi puta ne odbaci nulta hipoteza. Kada se prvi puta odbaci nulta hipoteza, zaključak je da je broj kointegracijskih vektora jednak *r* (*Asteriou i Hall, 2006, str.315-330*).

4.2.1.4. Testiranje Granger uzročnosti

Postojanje Granger uzročnost implicira da jedna varijabla uzrokuje promjenu druge varijable u vremenu i često se koristi u ekonomskim istraživanjima (*Jurčić et al., 2012*). *Granger (1969)* je razvio relativno jednostavan test koji definira uzročnost na sljedeći način: za varijablu y_t se može tvrditi da uzrokuje x_t, ukoliko se x_t može predvidjeti sa većom preciznošću korištenjem prošlih vrijednosti y_t varijable, nego u slučaju kada se prošle vrijednosti y_t varijable ne koriste (dok sve ostale varijable ostaju nepromijenjene).

Uobičajena definicija uzročnosti nalaže da promjene u jednoj varijabli uzrokuju promjene u drugoj varijabli. Grangerova uzročnost podrazumijeva pak mogućnost jedne varijable da predvidi dinamiku druge varijable, stoga se ispitivanje Granger uzročnosti varijabli (npr. X i Y) svodi na ispitivanje: koliki se dio dinamike varijable Y u tekućem periodu može objasniti dinamikom same varijable u prethodnim periodima i hoće li dinamika pojave Y biti bolje objašnjena ako se u analizu dodaju prethodne vrijednosti varijable. Smatra se da X uzrokuje Y ako varijabla X poboljšava predikciju varijable Y. Drugim riječima, Granger testom uzročnosti utvrđuje se nudi li varijabla x_t statistički značajnu informaciju o varijabli y_t, uz postojanje, prethodno definiranog, vremenskog odmaka. Ako to nije slučaj, prema Grangeru, x_t ne uzrokuje y_t.

Standardni Granger test uzročnosti moguće je primijeniti samo na stacionarne vremenske nizove, a makroekonomskim pokazateljima uglavnom je svojstvena nestacionarnost, stoga je nužan preduvjet provedbe testa uklanjanje jediničnog korijena (diferenciranjem).

4.2.1.5. Analiza stabilnosti modela

Nakon što je ispitana stacionarnost i kointegriranost vremenskih nizova generira se VAR model. Kada su podaci reda integriranosti jedan (I(1)), VAR model se najčešće procjenjuje u prvim diferencijama varijabli. Prethodno daljnjoj analizi ustanovljuje se stabilnost VAR modela kao garancija da su, kasnije generirane, funkcije impulsnog odziva i dekompozicija varijance točno izračunate, odnosu da su njihove procjene pouzdane. Prvi uvjet stabilnosti nalaže da se parametri karakterističnog polinoma nalaze unutar jediničnog kruga. Nakon što se zadovolji spomenuti uvjet, u nastavku se ispituju svojstva modela, odnosno reziduala; autokorelacija, normalnost i heteroskedastičnost.

Kako je već ranije istaknuto, važan korak u primjeni VAR metodologije je i odabir duljine (vremenskog) pomaka zbog osjetljivosti empirijske analize na izbor optimalne duljine pomaka varijabli. Ukoliko se red VAR-a određuje na osnovi informacijskih kriterija, računaju se njihove vrijednosti za svaki od modela AR*(m)* gdje je *m* pozitivan cijeli broj, a najbolji model je onaj koji ima najnižu vrijednost informacijskih kriterija. Kako bi odabir optimalne duljine odmaka bio što primjereniji, u analizi je korišteno nekoliko postupaka odabira duljine odmaka, često korištenih u primjeni VAR metodologije; multivarijantni informacijski kriteriji (Akaike informacijski kriterij – AIC[164], Schwarz informacijski kriterij – SC[165], Hannan-Quinn informacijski kriterij – HQ[166]), te sekvencijalni modificirani LR test. Detaljnije o informacijskim kriterijima može se vidjeti, primjerice, u *Asteriou i Hall (2006, str. 297-300).*

Važno je istaknuti da je odabir broja vremenskih odmaka u modelu važan i ne uvijek jednostavan zadatak. Iako se uvijek sugerira početi s procjenama koje uključuju veći broj odmaka, raspoloživost relativno kratkih vremenskih nizova predstavlja ograničenje. Nakon što se, temeljem predloženih informacijskih kriterija, i odredi broj vremenskih odmaka, poželjno je procjenu ponoviti i s nešto manjim brojem istih. Ako analiza pokaže da se s manjim brojem odmaka mogu dobiti jednako kvalitetni rezultati, bez da se naruše nužna svojstva procijenjenog modela, tada je uputno u konačnoj procjeni VAR modela smanjiti broj vremenskih odmaka jer se na taj način smanjuje i broj procijenjenih parametara. Nakon odabira optimalne duljine

[164] *Akaike (1974)*
[165] *Schwarz (1978)*
[166] *Hannan i Quinn (1979)*

odmaka, opravdanost odabira potvrđuje se dijagnostičkim testovima stabilnosti procijenjenog modela.

Prvi korak u procjeni stabilnosti modela odvija se korištenjem korijena AR karakterističnog polinoma. VAR model je stabilan ako su moduli svih korijena karakterističnog polinoma manji od jedan, odnosno ako leže unutar jediničnog kruga (po Euklidovoj normi). Ako navedeni uvjet nije zadovoljen, rezultati empirijske analize nisu primjereni (*Jurčić et al., 2012*).

Slijedi provjera svojstava reziduala procijenjenog VAR modela: LM testa autokorelacije, testa normalnosti oblika distribucije reziduala (uvjet koji najčešće na realnim ekonomskim nizovima podataka ne bude zadovoljen), te provjera heteroskedastičnosti. Navedena se procedura ponavlja za svaki procijenjeni VAR model.

U slučaju da postoji problem autokorelacije reziduala procjene parametara neće biti pouzdane, stoga ni zaključci temeljem istih neće biti ispravni. Zbog navedenih je razloga ključno „otkloniti“ problem autokorelacije iz procijenjenih VAR sustava jednadžbi. Najčešće se rješavanju problema autokorelacije prilazi na način da se korištene varijable logaritmiraju i/ili diferenciraju, što je kod ovdje korištenih varijabli već prethodno učinjeno. Ako problem autokorelacije nije riješen logaritmiranjem i diferenciranjem varijabli, isti se nastoji otkloniti smanjivanjem (ili povećavanjem)[167] broja vremenskih odmaka (na način da se isključuju oni kod kojih dijagnostički testovi ukazuju na postojanje problema autokorelacije reziduala). Alternativno je moguće generirati matricu koeficijenata korelacije unutar koje, izuzev dijagonalnih vrijednosti, niti jedan prikazani koeficijent korelacije (u apsolutnom iznosu) ne smije biti veći od 0,5.

4.2.1.6. Inovacijska analiza

Nakon procjene svih varijabli koje ulaze u model, VAR sustav se transformira u model pomičnih prosjeka (*engl. Moving Average representation*) kako bi se mogao analizirati odgovor sustava na naftni šok. Iako se VAR modeli primjenjuju u testiranju općih ekonomskih pretpostavki, glavni cilj VAR modela je u analizi dinamike skupine pojava dok procjene parametara modela nisu toliko važne same po sebi. U tu svrhu koristi se inovacijska analiza

[167] Optimalno je, s aspekta kriterija parsimonije, smanjivati odmake, ali se, alternativno, njihov broj može i povećavati ako je to u službi bolje dijagnostike modela.

koja podrazumijeva analizu funkcije impulsnog odziva (IRF) i dekompozicije varijance (VD). Prednost inovacijske analize je prikladna interpretacija parametara i jednostavnost donošenja zaključaka o dinamici varijabli (*Asteriou i Hall, 2006, str. 280-281*).

Funkcija impulsnog odziva prikaz je utjecaja „šoka“ od jedne standardne devijacije u pojedinim varijablama na jedinični „šok“ u endogenim varijablama sustava. Promjena u pojedinoj varijabli preko dinamičke strukture modela utječe na sadašnje i buduće vrijednosti svih endogenih varijabli (*Kennedy, 2003*). U makroekonomskom modeliranju IRFovi opisuju kako gospodarstvo reagira kroz određeni vremenski period na neki egzogeni impuls koji ekonomisti nazivaju „šok“ pri čemu se u samom modeliranju koristi VAR model. Primjenjivo na ovo istraživanje, IRF-ovi opisuju reakciju endogenih makroekonomskih pokazatelja, poput BDP-a, potrošnje, investicija, stope nezaposlenosti, u trenutku kad se šok (cijena nafte) dogodi, kao i kroz određeno (zadano) vrijeme nakon inicijalnog šoka.

Dok IRFovi ukazuju na smjer i intenzitet utjecaja naftnog šoka na preostale varijable u modelu, dekompozicija varijance analizira u kojoj je mjeri promjenjivost cijena nafte (dakle egzogenog šoka) odgovorna za promjenjivost ostalih varijabli u modelu. Dekompozicija varijance predočuje particiju varijance (kovarijance) prognostičke pogreške pojedine varijable na dijelove pridružene svim varijablama sustava (uključujući i samu varijablu). Analizom dekompozicije varijance uočavaju se najvažnije odrednice varijabilnosti endogenih varijabli analiziranih modela. Na temelju dobivenih rezultata moguće je analizirati, ne samo utjecaj pojedinačnih „šokova“ u varijablama na ostale varijable modela, već i relativni udio svake od varijabli u objašnjavanju varijacije određene varijable u narednim periodima (*Bahovec i Erjavec, 2009, str. 346*).

Nužno je istaknuti da je kod alata inovacijske analize (*IRF* i *VD*) koji se baziraju na poretku Choleskog važan poredak varijabli jer isti može, no ne mora nužno, utjecati na rezultate inovacijske analize. Sam poredak varijabli ne može se vršiti temeljem sugestije statističkih metoda (iako nerijetko rezultati testa Granger uzročnosti kao i Johansen testa kointegracije mogu biti od pomoći), već je najčešće na istraživaču odluka o samom poretku varijabli (za detalje vidjeti *Lütkepohl, 2005, str. 109-115*). Kod VAR modela s *n* varijabli postoji *n!* mogućih poredaka varijabli. Prilikom vršenja inovacijske analize, u sklopu provjere robusnosti rezultata, razmatrani su i alternativni poredci odabranih varijabli.

4.2.2. Operacionalizacija varijabli korištenih u istraživanju

U nastavku su opisane empirijskim istraživanjem obuhvaćene varijable počevši s korištenim pokazateljima cijena nafte.

Odabir varijabli napravljen je s ciljem obuhvaćanja relevantnih transmisijskih kanala naftnih cjenovnih šokova na gospodarstvo koji su identificirani proučavanjem teorije. Pri tom je iznimno važan odabir pokazatelja cijena nafte, pri čemu će u ovom istraživanju, slijedeći primjer *Jimenez-Rodriguez i Sanchez (2005)*, koristiti nekoliko pokazatelja. S obzirom da su novija istraživanja na razvijenim ekonomijama ukazala na „slabljenje" utjecaja cijena nafte na makroekonomske pokazatelje gospodarstava, umjesto klasičnih pokazatelja cijene nafte počinju se koristiti pokazatelji koji u sebi imaju ugrađenu pretpostavku asimetrije (o kojoj je već bilo riječi kroz eksplikaciju pojedinih hipoteza) kao i sve prisutniju volatilnost cijena nafte. Permutacijom u nastavku istaknutih pokazatelja izolirat će se pokazatelj koji podrazumijeva i najsnažniju reakciju gospodarstva na promjene cijena nafte, pri čemu će se ujedno pokazati i je li navedeni utjecaj asimetričan i je li važna sama promjena cijene nafte (bilo pozitivna ili negativna), učestalost te promjene, i/ili intenzitet cjenovnog pada/skoka u odnosu u prethodne povijesne vrijednosti cijena nafte. O važnosti ovakvog pristupa istraživanju svjedoče i *Löschel i Oberndorfera (2009)* koji naglašavaju važnost adekvatnog odabira primjerenog pokazatelja cijena nafte prilikom istraživanja njihovog utjecaja na pojedine makroekonomske varijable.

Sukladno navedenom, korištena su četiri pokazatelja promjene cijena nafte, odnosno na svakom mjestu gdje se u ponuđenim modelima javlja cijena nafte permutirana su četiri različita pokazatelja. To znači da su za svaku od postavljenih hipoteza (izuzev hipoteze H6) procijenjena četiri VAR modela (u model se uvrštavaju pokazatelji cijena nafte jedan po jedan). Kod svih je pokazatelja cijena nafte cijena izražena u USD.

Prvi pokazatelj je ujedno i najjednostavniji, a riječ je o realnim cijenama nafte koje se dobiju deflacioniranjem nominalnih cijena nafte indeksom cijena pri proizvođačima. Ovo je jedini linearni pokazatelj, dok su preostala tri pokazatelja nelinearna. Cijena nafte predstavljena je mjerilom (*engl. benchmark*) Dated Brent kojeg od 80ih godina prošlog stoljeća obračunava Platts[168] temeljem trgovinskih aktivnosti na tržištu nafte u Sjevernom moru. Riječ je o globalno

[168] https://www.platts.com/price-assessments/oil/dated-brent

najpoznatijem i najviše korištenom mjerilu (preostala dva su WTI – West Texas Intermediate za područje Amerike i Dubai Fateh za područje Azije). Po uzoru na istraživanje *Jimenez-Rodriguez i Sanchez (2005),* realna cijena nafte izračunata je kao omjer prosječne mjesečne (odnosno tromjesečne) Dated Brent cijene nafte (u američkim dolarima) koja je deflacionirana indeksom cijena pri proizvođačima SAD-a (*engl. PPI – Producer Price Index*). Ovako definirana realna cijena nafte anulira utjecaj inflacije *(Hamilton, 1996)* a ujedno predstavlja jedinstven pokazatelj promjene cijena nafte na globalnoj razini, što omogućuje i usporedivost s istraživanjima koja ju koriste kao pokazatelj *(Mork, 1989; Lee et al., 1995; Carruth et al., 1998; Hooker, 1996, 1999; Jimenez-Rodriguez i Sanchez, 2005; i dr.).* Iako postoje studije u kojima se cijene nafte denominiraju u nacionalnim valutama, ovako definiran naftni šok nije jedinstven svim promatranim zemljama i zbog toga je neopravdano uspoređivati empirijske rezultate koje koriste takove cijene nafte. Nadalje, literatura o utjecaju cijena nafte na SAD ne koristi Dated Brent cijenu već WTI, no između Brent i WTI postoji visok koeficijent korelacije čime se opravdava korištenje Dated Brent pokazatelja. Potonje se mjerilo koristi za otprilike 67% globalne fizičke trgovine sirovom naftom (*Davis, 2012*) zbog čega se i uobičajeno koristi kao pokazatelj svjetske cijene nafte (za Europu i Afriku gotovo isključivo; *Speight, 2017*). Navedeno je posebno izraženo nakon perioda od 2010. do 2014. kada je WTI bio znatno niži (vidjeti Grafikon 2.3.1.1.) te kao takav nije bio mjerodavan pokazatelj svjetskih cijena nafte u danom periodu.

Drugi pokazatelj, predložen od strane *Morka (1989),* promatra periode rasta i pada cijena nafte kao odvojene nizove. Navedena specifikacija cijena nafte razlikuje pozitivne i negativne stope promjene kako slijedi:

MORK+: $o_t^+ = o_t; o_t > 0 \qquad o_t^+ = 0; o_t \leq 0$ (4.11.)

MORK-: $o_t^- = o_t; o_t < 0 \qquad o_t^- = 0; o_t \geq 0$ (4.12.)

gdje je o_t stopa promjene realne cijene nafte.

Pokazatelj izlučuje dva vremenska niza postotne promjene cijena nafte, gdje prvi, o_t^+, uključuje samo pozitivne postotne promjene cijena nafte (ako je promjena cijene negativna, pokazatelj o_t^+ poprima vrijednost 0), a drugi, o_t^-, negativne postotne promjene cijena nafte (ako je promjena cijene pozitivna, pokazatelj o_t^- poprima vrijednost 0).

Sljedeći pokazatelj uvažava i volatilnost cijena nafte, a riječ je o tzv. „scale“ pokazatelju *(Lee et al., 1995)*, ili pokazatelju promjenjivosti cijena nafte. Ovaj se model naslanja na *Morkov (1989)* asimetrični pokazatelj pri čemu koristi transformaciju cijena nafte koja vlastitom vremenskom promjenjivošću (varijabilnošću) standardizira procijenjene reziduale autoregresijskog modela. *Lee et al.* sugeriraju sljedeći AR (4) – GARCH (1,1) model cijena nafte:

$$o_t = \alpha_0 + \alpha_1 o_{t-1} + \alpha_2 o_{t-2} + \alpha_3 o_{t-3} + \alpha_4 o_{t-4} + e_t \tag{4.13.}$$

$$e_t | I_{t-1} \qquad N(0, h_t) \tag{4.14.}$$

$$h_t = \gamma_0 + \gamma_1 e_{t-1}^2 + \gamma_2 h_{t-1} \tag{4.15.}$$

$$SOPI = \max(0, \hat{e}_t \Big| \sqrt{\hat{h}_t}) \tag{4.16.}$$

$$SOPD = \min(0, \hat{e}_t \Big| \sqrt{\hat{h}_t}) \tag{4.17.}$$

gdje SOPI predstavlja poraste (*engl. Scaled Oil Price Increase*), a SOPD (*engl. Scaled Oil Price Decrease*) padove cijena (o_t i u ovom modelu predstavlja stopu promjene realne cijene nafte). Valja istaknuti da se ovdje radi u uvjetnim sredinama i uvjetnim varijancama (dvije su jednadžbe) jer su one uvjetovane (*engl. conditional*) skupom informacija I(t-1).

Konačno, *Hamilton (1996)* predlaže nešto drugačiju nelinearnu transformaciju cijena nafte, tzv. neto porast cijena nafte (*engl. Net Oil Price Increase - NOPI*). Ovaj je pokazatelj definiran kao iznos (točnije, logaritam iznosa) za koji cijene nafte u kvartalu (odnosno mjesecu) t, premašuju maksimalnu vrijednost cijena nafte kroz prethodna četiri kvartala (mjeseca), u protivnom, ako spomenuti maksimum nije premašen, varijabla poprima vrijednost nula. Na ovaj se način uvažava asimetričnost utjecaja cijena nafte na BDP.

$$NOPI = 100 \cdot \log\left(\frac{p_t}{\max(p_{t-1}, \ldots, p_{t-4})}\right)^+ \tag{4.18.}$$

Za razliku od prethodnog pokazatelja, Hamiltonov NOPI uzima u obzir samo poraste cijena smatrajući da pad cijena nafte (zaključak temeljen na rezultatima istraživanja na SAD-u) nema statistički značajan efekt na gospodarstvo; dakle, asimetrija je ugrađena u postavke samog pokazatelja. Ono što je također iznimno važno istaknuti kod posljednja dva pokazatelja cijena

je i činjenica da oba uvažavaju efekt iznenađenja kao ključan element utjecaja cijena nafte na gospodarstvo. Efekt iznenađenja nalaže da jednako snažna promjena cijene nafte može izazvati jaču reakciju gospodarstva ako uslijedi nakon perioda skromnih fluktuacija cijena nafte.

Nužno je naglasiti da se navedene specifikacije pokazatelja cijena nafte odvojeno računaju ovisno o frekvenciji podataka: tromjesečnoj ili mjesečnoj. Tako $t=1$ kod analize tromjesečnih vremenskih nizova označava jedno tromjesečje, a kod analize mjesečnih vremenskih nizova jedan mjesec.

U istraživanju su korišteni kvartalni, odnosno mjesečni podaci i to za period od početka 1995. (siječanj, odnosno prvo tromjesečje) do kraja 2015. godine (prosinac, odnosno posljednje tromjesečje). Kod pojedinih hipoteza vremenski niz je ograničen dostupnošću podataka, čemu su prilagođeni i vremenski nizovi u modelu. To je učinjeno imajući u vidu posebno velik problem i prepreku, na koju redovito nailaze svi korisnici statističkih podataka u Hrvatskoj, a to je stalno prepravljanje, naknadno preračunavanje i nerijetko iskazivanje različitih podataka za istu pojavu, čak u isto vrijeme od različitih institucija (*Barić i Čavrak, 2005*).

Varijable obuhvaćene istraživanjem navedene su u sklopu Tablice 4.2.2.1. koja, pored naziva varijable u drugom stupcu navodi mjernu jedinicu izvornog vremenskog niza kao i izvor podataka. Slijedi definiranje obuhvata varijabli, kao i njihova operacionalizacija.

Sezonske varijacije vremenskog niza značajno utječu na njegovu ukupnu varijancu pa će prognoze koje zanemaruju važnost sezonske komponente imati veliku varijancu (prognostičku pogrešku). Zato je potrebno, u slučaju sezonskih varijacija pojave, empirijsku analizu provoditi nad desezoniranim (vremenski prilagođenim) podacima, to jest na temelju vremenskog niza iz kojeg su uklonjeni sezonski utjecaji. Pored vremenskih nizova koji su preuzeti u desezoniranom obliku (CPI, NEER, REER, UNP), postupak desezoniranja izvršen je uz pomoć TRAMO/SEATS metode i to kod vremenskih nizova varijabli: BDP, CONS, INV, IPI, DI, WAGEr i M1.

U pojedinim slučajevima korištene su logaritamske vrijednosti promatranog vremenskog niza jer se smatra da ovakva transformacija stabilizira varijancu vremenskog niza, što potencira veću preciznost rezultata daljnje statističko-ekonometrijske analize (*Lütkepohl i Xu, 2009*). U skladu s navedenim, u istraživanju su korištene logaritamske transformacije varijabli: OIL, OILN,

FUEL (ES95 i EURODIZEL), BDP, IPI, REER, NEER, WAGE, DI, PPI, CPI, M1, INV i CONS. U nastavku je iznijet kratak opis u istraživanju korištenih varijabli.

Tablica 4.2.2.1.: Popis varijabli

Varijabla	Naziv	Izvor podataka*
Pokazatelji cijena nafte (u USD/barel)	OILN, OIL, MORK+, MORK-, SOPI, SOPD, NOPI	EIA, kalkulacije autorice
Cijene naftnih derivata (u kn/l)	FUEL	MINGO/MZOE
Realni bruto domaći proizvod (u mil. kn)	BDP	DZS/Eurostat
Indeks industrijske proizvodnje (2010=100)	IPI	DZS
Realni efektivni devizni tečaj (2010=100)	REER	HNB
Nominalni efektivni devizni tečaj (2010=100)	NEER	HNB
Prosječna neto realna plaća	WAGE	DZS
Neto raspoloživi dohodak/RMP	DI	HNB/DZS
Stopa nezaposlenosti (%)	UNP	DZS/HZZ
Indeks cijena pri proizvođačima (2010=100)	USA PPI, HR PPI	HNB
Indeks potrošačkih cijena (2010=100)	CPI	HNB
Monetarni agregat M1 (u mil. kn)	M1	HNB
Realna kamatna stopa (%)	IR	HNB
Realne investicije (u mil. kn)	INV	DZS/Eurostat
Realna osobna potrošnja (u mil. kn)	CONS	DZS/Eurostat

*EIA - U.S. Energy Information Administration, MINGO - Ministarstvo gospodarstva, poduzetništva i obrta, MZOE - Ministarstvo zaštite okoliša i energetike, DZS - Državni zavod za statistiku, HNB - Hrvatska narodna banka, HZZ - Hrvatski zavod za zapošljavanje
Izvor: djelo autorice

Realni bruto domaći proizvod (BDP)

Podaci o BDP-u[169], kao i njegovim komponentama – osobnoj potrošnji i investicijama, obračunati su po rashodnoj metodi, a iskazani su u stalnim cijenama, odnosno u cijenama referentne 2010. godine. Kako su tromjesečni podaci dostupni tek od prvog tromjesečja 2000. godine, podaci za ranije razdoblje (od 1995.) aproksimirani su *Chow-Lin* (*Chow i Lin, 1971*) metodom temporalne dezagregacije (isto vrijedi i kod varijabli osobne potrošnje i bruto investicija u fiksni kapital)[170].

Kao alternativa korištenju realnog BDP-a, korišteni su, kako je već i rađeno u literaturi *(Erjavec et al., 1999; Erjavec i Cota, 2003; Lang i Krznar, 2004; Vizek, 2006),* **indeks fizičkog obujma industrijske proizvodnje (IPI)**, čiji su podaci dostupni na mjesečnoj bazi. Iako se udio

[169] Za detaljna metodološka pojašnjenja podataka DZS-a *cf. DZS (2016), Statistički ljetopis Republike Hrvatske 2016,* Godina 48., Zagreb, Prosinac 2016., ISSN 1333-3305
[170] Za više detalja cf. *Dagum i Cholette (2006)*

industrijske proizvodnje u ukupnoj proizvodnji smanjuje već drugo desetljeće, činjenica je da su ciklusi industrijskog sektora usklađeni s cikličkim obrascem kretanja bruto domaćeg proizvoda. To je stoga što upravo industrijski sektor na sebe veže sve ostale sektore, a ujedno je najosjetljiviji *(Cerovac, 2005).*

Realne investicije (INV)

Investicije su predstavljene pokazateljem bruto investicija u fiksni kapital (*engl. gross fixed capital formation*), odnosno dugotrajnu imovinu. Bruto investicije u dugotrajnu imovinu obuhvaćaju investicije u novu dugotrajnu imovinu, troškove transakcija rabljene dugotrajne imovine te nabave nematerijalne dugotrajne imovine. Podaci o investicijama preuzeti su od DZS-a koji ih obračunava pomoću metode robnih tokova, a vremenski niz deflacionira indeksima cijena proizvođača domaćih i uvoznih kapitalnih dobara te implicitnim deflatorom za građevinarstvo iz obračuna BDP-a prema proizvodnom pristupu. Bruto investicije u fiksni kapital ne uzimaju u obzir amortizaciju postojeće akumulacije kapitala[171].

Realna osobna potrošnja (CONS)

Osobna potrošnja predstavljena je podacima DZS-a o finalnoj potrošnji kućanstava. Finalna potrošnja kućanstava obuhvaća izdatke za hranu i bezalkoholna pića, alkoholna pića i duhan, odjeću i obuću, stanovanje, pokućstvo, zdravstvo, prijevoz, komunikacije, rekreaciju i kulturu, obrazovanje, ugostiteljske usluge, ostala dobra i usluge. Grupe osobne potrošnje sastavljene su prema klasifikaciji osobne potrošnje prema namjeni – COICOP (Classification of Individual Consumption by Purpose).

Nominalni (NEER) i realni efektivni devizni tečaj (REER)

Indeks nominalnoga efektivnog tečaja agregatni je pokazatelj prosječne vrijednosti domaće valute prema košarici stranih valuta[172]. Povećanje indeksa nominalnoga efektivnog tečaja kune u određenom razdoblju pokazatelj je deprecijacije tečaja kune prema košarici valuta i obratno.

[171] Investicije su dinamična veličina (prikazuju tijek), za razliku od kapitala koji prikazuje stanje. Na taj način promjena kapitala u određenom vremenskom razdoblju podrazumijeva razliku investicija i amortizacije tijekom godine. Ovo je iznimno važno s aspekta sagledavanja tijeka investicija u kriznim periodima, jer oni nerijetko znaju biti veoma blizu stopama amortizacije što znači da se „investiranjem“ samo održava trenutna razina kapitala, odnosno, kapital, unatoč poduzetim investicijama ne raste.

[172] Skupinu zemalja za formiranje indeksa efektivnih tečajeva kune čini 20 zemalja partnera, a to su: a) iz euro zone osam zemalja: Austrija, Belgija, Francuska, Njemačka, Italija, Nizozemska, Slovenija i Španjolska; b) iz EU-a, a izvan euro zone, pet zemalja: Češka, Madžarska, Poljska, Švedska i Velika Britanija te c) izvan EU-a sedam zemalja: Bosna i Hercegovina, Japan, Kina, SAD, Srbija, Švicarska i Turska.

Indeks realnoga efektivnog tečaja ponderirani je geometrijski prosjek indeksa bilateralnih tečajeva kune korigiranih odgovarajućim indeksima relativnih cijena ili troškova (odnos indeksa cijena ili troškova u zemljama partnerima i domaćih cijena). Nizovi baznih indeksa izračunati su na bazi 2010. godine i preuzeti sa mrežnih stranica HNB-a. Za deflacioniranje je korišten indeks potrošačkih cijena na način da su do prosinca 1997. godine korišteni indeksi cijena na malo, a od siječnja 1998. indeksi potrošačkih cijena. Podaci o realnom efektivnom tečaju za posljednji su mjesec (prosinac 2015.) preliminarni.

Valja imati na umu da utjecaj naftnog šoka ovisi i o bilateralnom tečaju američkog dolara i valute promatrane zemlje (jer se nafta i plaća/kupuje američkim dolarima). Ovako definirana cijena nafte potencijalno može maskirati (*engl. blur*) identifikaciju samog šoka. Iako postoje studije u kojima se cijene nafte denominiraju u nacionalnim valutama, ovako definiran naftni šok nije jedinstven svim promatranim zemljama i zbog toga je neopravdano uspoređivati empirijske rezultate među različitim gospodarstvima. Iako devizni tečaj može utjecati na cijenu nafte na nacionalnoj razini, bilateralni devizni tečaj nije uključen u istraživanje, ali je zato uključena varijabla REER, šira definicija tečaja koja uključuje i bilateralni tečaj američkog dolara i hrvatske kune. Ovakav tečaj je odabran jer uključuje i tečaj eura u odnosu na kunu, čime se uzima u obzir visoki stupanj euroizacije gospodarstva kao hrvatska specifičnost. U konačnici, kako ističe *Malešević-Perović (2009)*, „Efektivni tečaj temelji se na skupnom utjecaju različitih tečajeva te na bolji način objašnjava posljedice promjene tečaja na gospodarstvo“. Osim toga, usprkos nastojanjima središnje banke da tečaj kune prema euru održi relativno stabilnim, kretanja na globalnim financijskim tržištima određuju tečaj kune prema ostalim valutama, koji može značajno utjecati na pojedine sektore gospodarstva. Stoga i *Bukovšak et al. (2017)* smatraju primjerenim korištenje obuhvatnijeg pokazatelja tečaja jer je on standardna mjera cjenovne konkurentnosti i prikladniji za procjenu ukupnih makroekonomskih kretanja.

Stopa nezaposlenosti (UNP)

Podaci o stopi nezaposlenosti predstavljeni su podacima o anketnoj stopi nezaposlenosti čije mjerenje je, imajući u vidu međunarodnu usporedivost podataka, u skladu s definicijom Međunarodne organizacije rada (*engl. International Labour Organisation*) s čijom su definicijom usklađeni i standardi Eurostata. Iako u slučaju RH postoje različite statistike nezaposlenosti (od strane HZZ-a, DZS-a, HNB-a), odluka o korištenju anketne stope

nezaposlenosti Eurostata utemeljena je na međunarodnoj usporedivosti podataka o stopi nezaposlenosti.

Radna snaga je zbroj zaposlenih i nezaposlenih osoba dobi od 15 do 74 godine, pri čemu se osoba smatra nezaposlenom ako je nezaposlena u promatranom tjednu, spremna za prihvaćanje posla u naredna dva tjedna ili je pronašla posao koji započinje unutar naredna tri mjeseca. Korišteni su mjesečni podaci Eurostata raspoloživi za period od siječnja 2000. do prosinca 2015.

Realne plaće (WAGE)

Realne plaće, za razliku od nominalnih, uzimaju u obzir utjecaj inflacije s ciljem preciznijeg mjerenja promjena u kupovnoj moći kroz vrijeme. Podaci o realnim plaćama izračunati su uz pomoć (mjesečnih) podataka o prosječnim nominalnim mjesečnim plaćama (DZS) korigiranim za utjecaj inflacije (HNB). Prema definiciji DZS-a, prosječna 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, zastoje 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.

Jedna od varijabli istraživanja, **realna masa plaća,** korištena je kao pokazatelj *neto raspoloživog dohotka (DI).* DZS, na temelju Ankete o potrošnji kućanstava, raspolaže relevantnim podacima o raspoloživom dohotku (*disposable income*) kućanstva samo na godišnjoj razini za period 1998-2011 (nakon čega se periodika promijenila u višegodišnju). Alternativno, po uzoru na *Tica i Rosan (2014*) koji su istraživali čimbenike kretanja funkcije realne potrošnje kućanstva u RH, raspoloživi dohodak je aproksimiran realnom masom plaća. Navedeni su autori ovaj podatak dobili množenjem prosječne realne plaće i ukupnog broja zaposlenih. Kako DZS službene podatke o prosječnoj plaći u RH objavljuje za zaposlene u pravnim osobama (što nije ukupan broj zaposlenih; nema obrtnika, slobodnih zanimanja, poljoprivrednika), u ovom je istraživanju realna masa plaća aproksimirana umnoškom realne prosječne plaće i broja zaposlenih u pravnim osobama. Što se tiče broja zaposlenih u pravnim osobama, oni čine cca 80% ukupno zaposlenih (početkom perioda istraživanja njihov udio je bio malo ispod 80% pa je s vremenom lagano rastao, na, primjerice, 85% u 2015., prema evidencijama HZMO-a).

Indeks cijena pri proizvođačima (PPI) i Indeks potrošačkih cijena (CPI)

Često se pretpostavlja usporedno kretanje navedenih dvaju indeksa; međutim, to često nije slučaj jer upravo konceptualne i definicijske razlike među njima doprinose različitim kretanjima promatranih indeksa. PPI mjeri cijene dobara i usluga koje kupuju proizvođači, odnosno promjenu istih kroz vrijeme, dok CPI mjeri cijene dobara i usluga koje kupuju potrošači, odnosno promjenu istih kroz vrijeme. I PPI i CPI mjere promjenu cijena kroz vrijeme za fiksnu skupinu dobara pri čemu je primarna upotreba PPI deflacioniranje toka prihoda kako bi se mjerio realni rast proizvodnje, dok CPI odražava promjene u razini cijena dobara i usluga koje u tijeku vremena nabavlja, koristi se njima ili ih plaća referentno stanovništvo (privatna kućanstva) radi potrošnje.

CPI se izračunava i objavljuje od siječnja 2004. kao jedinstvena i opća mjera inflacije u RH. Retroaktivno je izrađen i CPI niz unatrag do siječnja 1998., otkad je u primjeni klasifikacija COICOP (*DZS, 2018, str. 7.*). Kao mjerilo inflacije u razdoblju prije 1998. godine, DZS je izračunavao i objavljivao indeks cijena na malo; stoga je za period prije 1998. CPI aproksimiran uz pomoć kretanja baznih indeksa cijena na malo.

Monetarni agregat M1 (M1)

Monetarni agregat M1, primarni novac, obuhvaća količinu novca u opticaju čemu se pridodaju *a vista* (prekonoćni) depoziti, te će se koristiti kao pokazatelj kretanja novčane mase. Novčana masa M1 obuhvaća gotov novac izvan kreditnih institucija, depozite ostalih financijskih institucija kod HNB-a te depozitni novac kod kreditnih institucija.

Kamatna stopa (IR)

HNB nema referentnu kamatnu stopu kao definirani instrument monetarne politike, kao što je slučaj kod središnjih banaka (primjerice Europske središnje banke) koje koriste kamatni kanal u ostvarivanju osnovnog cilja monetarne politike. Kao pokazatelj kamatne stope korištena je kamatna stopa na tržištu novca, tzv. *money market interest rate*, odnosno međubankarska kamatna stopa (na prekonoćne kredite). Riječ je o kamatnoj stopi po kojoj banke na nacionalnom tržištu razmjenjuju sredstva.

Cijene naftnih derivata (ES95/Eurodiesel)

Za prosječne cijene naftnih derivata korištene su mjesečna (tromjesečna) prosječne cijene naftnih derivata; bezolovnog motornog benzina i dizela, odnosno Eurosuper 95 i Eurodizel,

(bez poreza i trošarina) deflacionirate indeksom potrošačkih cijena. Eurosuper 95 uveden je na hrvatsko tržište u ožujku 2004. godine. Cijene do tog mjeseca su cijene INA bezolovnog motornog benzina 95 (INA BMB 95). Eurodizel je na hrvatsko tržište uveden u travnju 2001. godine. Cijene do tog mjeseca su cijene INA dizel goriva (INA DG). Kod navedenih cijena riječ je o INA-inim prosjecima što se može smatrati relevantnim s obzirom na (iako kroz analizirani period opadajući) prevladavajući udio INA-e na maloprodajnom tržištu naftnih derivata u RH.

Pored navedenih makroekonomskih varijabli, u istraživanju je korištena i dihotomna **dummy varijabla KRIZA** s vrijednošću 1 u tromjesečjima (mjesecima) u kojima je gospodarstvo bilo u krizi, odnosno s oznakom 0 u protivnom. Kao pokazatelj krize promatra se stopa rasta realnog BDP-a. Slijedom navedenog, dummy varijabla KRIZA ima vrijednost 1 u periodu od 2008:Q4 do 2014:Q3, dok u preostalim tromjesečjima (mjesecima) odabranog perioda analize (od 1995:Q1 do 2015:Q4) ima vrijednost 0.

4.3. PRELIMINARNA ANALIZA KORIŠTENIH VREMENSKIH NIZOVA

U sklopu ovog poglavlja prikazani su rezultati deskriptivne statistike za korištene vremenske nizove. S obzirom na činjenicu da su u istraživanju korišteni tromjesečni i mjesečni podaci, kroz naredne su dvije tablice predstavljene temeljne statističke odlike korištenih tromjesečnih i mjesečnih vremenskih nizova u periodu od 1995. do 2015. godine; mjerna jedinica izvornog vremenskog niza, aritmetička sredina, medijan, maksimalna i minimalna vrijednost te standardna devijacija. Tablicama 4.3.1. i 4.3.2. prikazana je deskriptivna statistika korištenih tromjesečnih odnosno mjesečnih vremenskih nizova.

S obzirom na usmjerenost istraživanja na cijene nafte, ovdje se posebno može istaknuti relativno visoka standardna devijacija kao i raspon između minimalne i maksimalne cijene nafte po barelu neovisno o tome jesu li iste iskazane u USD/barelu na tromjesečnoj ili mjesečnoj razini. Navedeno ide u prilog ranijim navodima o visokoj volatilnosti cijena nafte.

Preliminarna analiza korištenih vremenskih nizova podrazumijeva i testiranje svojstava vremenskih nizova ranije opisanim testovima jediničnog korijena. Ipak, kako se vremenski obuhvat, kao i frekvencija korištenih vremenskih nizova, donekle razlikuje kod pojedinih

hipoteza, tako je i navedena analiza integrirana kroz naredna potpoglavlja unutar kojih se vrši empirijska provjera postavljenih hipoteza.

Tablica 4.3.1.: Deskriptivna statistika korištenih tromjesečnih vremenskih nizova

Varijabla	Mjerna jedinica	Aritmetička sredina	Medijan	Maksimum	Minimum	Standardna devijacija
REER	2010=100	108,09	107,64	122,73	96,91	6,37
BDP	x 10^6 HRK	74 145,0	75 945,59	95 403,24	51 664,44	10 915,71
CONS	x 10^6 HRK	43 115,14	44 293,23	55 568,94	31 203,43	6 143,02
INV	x 10^6 HRK	15 736,72	16 112,79	26 595,78	5 431,88	4 389,53
IPI	2010=100	92,13	93,15	115,43	67,7	11,61
CPI	2010=100	86,62	85,58	108,59	60,48	15,04
OILr	USD/barel	57,99	51,88	114,28	16,73	28,86
SOPD	/	-0,35	0,00	0,00	-5,28	0,77
SOPI	/	3,02	0,14	211,15	0,00	23,72
NOPI4	%	1,35	0,00	11,45	0,00	2,38
MORK-	%	-4,21	0,00	0,00	-45,56	7,85
MORK+	%	5,74	2,03	36,09	0,00	7,62
KRIZA	0-1	0,27	0,00	1,00	0,00	0,45
DI	x 10^6 HRK	6 193,96	6 230,18	7 425,17	4 899,87	653,69
WAGEr	HRK	5 054,28	5 458,9	5 912,68	3 118,64	777,65
IRr	%	2,54	0,92	26,22	-3,64	5,13
UNP	%	13,71	14,05	17,60	8,30	2,74

Izvor: izračun autorice

S obzirom na jako veliki broj tablica (ispisa programskog paketa Eviews 8) koji su nužni za obradu podataka, sam tekst disertacije je rasterećen od istih na način da se kroz u tekstu prikazane tablice, gdje god je to moguće, prikazuju samo finalni rezultati pojedinih procjena i testova programskog paketa Eviews 8. Zbog postavki istraživanja koje podrazumijevaju permutiranje različitih pokazatelja cijena nafte u jednako definiranim početnim oblicima VAR modela, na ovaj način je pojednostavljena i usporedivost rezultata procijenjenih VAR modela koji koriste različite pokazatelje cijena nafte za provjeru iste hipoteze.

Tablica 4.3.2.: Deskriptivna statistika korištenih mjesečnih vremenskih nizova

Varijabla	Mjerna jedinica	Aritmetička sredina	Medijan	Maksimum	Minimum	Standardna devijacija
REER	2010=100	108,08	107,71	123,31	96,37	6,40
NEER	2010=100	102,97	102,29	112,82	96,82	3,83
M1	x 10^6 HRK	35 354,15	36 721,65	70 662,71	6 512,52	18 318,22
CPI	2010=100	86,86	85,74	108,66	60,42	15,11
IPI	2010=100	92,13	92,85	119,4	65,5	12,39
OILN	USD/barel	54,54	46,0	132,72	9,82	35,40

SOPD	/	-0,41	0,00	0,00	-3,37	0,67
SOPI	/	0,39	0,16	1,99	0,00	0,48
NOPI4	%	0,79	0,00	8,36	0,00	1,56
MORK-	%	-2,97	0,00	0,00	-22,75	4,98
MORK+	%	3,49	0,94	22,22	0,00	4,70
KRIZA	0-1	0,28	0,00	1,00	0,00	0,45
WAGEr	HRK	4 707,22	5 053,22	5 585,94	2 852,16	727,14
IR	%	6,16	3,27	30,01	0,38	6,62
UNP	%	13,71	14,00	17,70	8,30	2,73
LOIL*	HRK/l	2,43	2,32	4,51	0,97	1,00
ES95*	HRK/l	3,53	3,40	5,99	1,77	1,08
DIESEL*	HRK/l	3,78	3,72	6,21	1,70	1,22

* 2000:M01-2015:M12
Izvor: izračun autorice

4.4. FORMULACIJA I TESTIRANJE EMPIRIJSKIH MODELA

Slijedom prezentiranog konceptualnog modela, kao i formulacije empirijskih modela koji se naslanjaju na ranije iznijetu teorijsku podlogu o utjecaju cijena nafte na makroekonomske pokazatelje, u nastavku je prezentirana empirijska provjera sljedećih hipoteza istraživanja:

H1: Promjene cijena nafte statistički značajno negativno utječu na stopu rasta bruto domaćeg proizvoda hrvatskog gospodarstva.

H2: Promjene cijena nafte statistički značajno pozitivno utječu na kretanje inflacije.

H3: Rast cijena nafte statistički značajno povećava nezaposlenost, dok pad cijena nafte nema statistički značajan utjecaj na nezaposlenost.

H4: Promjene cijena nafte statistički značajno negativno utječu na kretanje osobne potrošnje.

H5: Promjene cijena nafte statistički značajno utječu na kretanje investicija.

H6: Cijene naftnih derivata asimetrično reagiraju na promjenu cijene nafte.

4.4.1. Međuodnos cijena nafte i stope promjene bruto domaćeg proizvoda

Kako bi se testirala postavljena hipoteza H_1: *Promjene cijena nafte statistički značajno negativno utječu na stopu rasta bruto domaćeg proizvoda hrvatskog gospodarstva*, konstruirana su 4 VAR modela permutiranjem prethodno predloženih pokazatelja cijena nafte. Općim oblikom VAR modela (4.4.) obuhvaćene su tromjesečne varijable *Zt* vektora, za period 1995:Q1-2015:Q4; *LBDP* (u stalnim cijenama 2010.), *LIPI* (2010=100), *LREER* (2010=100),

LOIL - prirodni logaritam realne cijene nafte (odnosno pripadajući pokazatelj cijene nafte; *LOIL, MORK+, MORK-, SOPI, SOPD, NOPI4*), te dummy varijabla - *KRIZA*.

Na ovom je mjestu nužno istaknuti da je ovdje pojašnjena analiza provedena i korištenjem istovjetnih varijabli u periodu za kojeg su dostupni izvorni tromjesečni podaci, od 2000:Q1 do 2015:Q4. Isto je učinjeno iz dva razloga, prvi razlog je bio nedostupnost izvornih tromjesečnih podataka za prethodni period, a drugi, važniji, ranije istaknuta činjenica da su se u Republici Hrvatskoj maloprodajne cijene naftnih derivata po tzv. tržišnoj formuli počele obračunavati tek od 2000. godine. Ipak, rezultati analize nad skraćenim vremenskim nizovima producirali su gotovo jednake (u smislu statističke značajnosti i smjera utjecaja među odabranim varijablama veoma slične) zaključke ekonometrijske analize. Zbog toga se sa ekonometrijskog stanovišta može zaključiti da je primjerenije analizirati dulji vremenski niz (koji je, u ovom slučaju, čak i u tom obliku relativno kratak), a jednako tako i da je utjecaj cijena nafte na makroekonomske pokazatelje producirao usporedive efekte čak i kad se obuhvate podaci prethodno periodu uvođenja tzv. formule za izračun cijena naftnih derivata. Potonje bi značilo da su, unatoč većinskom državnom vlasništvu najveće naftne tvrtke (INA-e), maloprodajne cijene naftnih derivata u zadovoljavajućoj mjeri pratile kretanja na svjetskim tržištima (čak i koncem 1990ih godina). Zbog svega navedenog daljnja ekonometrijska analiza provedena je za period 1995:Q1-2015:Q4.

U prvom koraku analize, testovima jediničnog korijena, provedeno je ispitivanje stohastičkih svojstava korištenih vremenskih nizova. Rezultati istog prikazani su u sklopu Tablice 4.4.1.1., Statistička značajnost t-omjera prikazanih unutar tablice prikazana je naznakom zvjezdica uz broj unutar ćelije pri čemu zvjezdice označavaju odbacivanje nulte hipoteze provedenog testa (kako je ranije već pojašnjeno) na razini od 1%, 5% i 10% (redoslijedno: ***,**,*).

Evidentno je da su odabrane (unutar tablice podebljane) varijable nestacionarne u razinama te da je stacionarnost postignuta diferenciranjem[173]. Uz visoke razine pouzdanosti može se zaključiti da su varijable realna cijene nafte, realni BDP, indeks industrijske proizvodnje kao i realni efektivni devizni tečaj integrirane reda jedan; I(1), dok su preostali pokazatelji cijena nafte (MORK+/MORK-, SOPI/SOPD, NOPI4) stacionarni u razinama, odnosno integrirani

[173] Izuzetak su MORK+, MORK-, SOPI, SOPD i NOPI4 koji su stacionarni u razinama, odnosno integrirani reda nula (I(0)).

reda nula, I(0). Temeljem rezultata testova jediničnog korijena, daljnja analiza se nastavlja korištenjem stacionarnih vremenskih nizova: DLBDP (prva diferencija prirodnog logaritma realnog BDP-a), DLIPI (prva diferencija prirodnog logaritma indeksa industrijske proizvodnje, DLREER (prva diferencija prirodnog logaritma realnog efektivnog deviznog tečaja) te stacionarnih pokazatelja cijena nafte; DLOIL, MORK+, MORK, SOPI, SOPD i NOPI4. S obzirom da je ovdje odabrana varijabla od interesa BDP stacionarna tek nakon diferenciranja, stacionarni oblik korištene varijable (prva diferencija prirodnog logaritma BDP) je, u stvarnosti, stopa rasta BDP-a.

Tablica 4.4.1.1.: Rezultati testova jediničnog korijena za korištene vremenske nizove, tromjesečni podaci (1995:Q1-2015:Q4)

	Model s konstantom i trendom			Model s konstantom			Model bez konstante	
	ADF	PP	KPSS	ADF	PP	KPSS	ADF	PP
LOIL	-1,96	-1,37	0,15***	-1,71	-1,6	0,96***	0,03	0,22
DLOIL	**-6,98*****	**-6,86*****	**0,09**	**-6,93*****	**-6,83*****	**0,22**	**-6,95*****	**-6,87*****
MORK+	**-6,88*****	**-6,72*****	**0,12**	**-6,84*****	**-6,72*****	**0,24**	**-4,97*****	**-4,86*****
MORK-	**-7,22*****	**-7,22*****	**0,07**	**-7,20*****	**-7,22*****	**0,12**	**-5,91*****	**-6,03*****
SOPI	**-8,79*****	**-8,79*****	**0,07**	**-8,82*****	**-8,82*****	**0,11**	**-8,73*****	**-8,73*****
SOPD	**-8,46*****	**-8,45*****	**0,05**	**-8,46*****	**-8,46*****	**0,11***	**-7,16*****	**-7,25*****
NOPI4	**-6,07*****	**-6,07*****	**0,08**	**-5,98*****	**-6,03*****	**0,18***	**-4,95*****	**-4,95*****
LBDP	-1,33	-1,25	0,27***	-2,33	-2,46	0,95***	2,36	2,38
DLBDP	**-11,69*****	**-11,47*****	**0,09**	**-11,15*****	**-10,96*****	**0,49****	**-10,41*****	**-10,45*****
LIPI	-1,14	-1,05	0,26***	-1,72	-1,73	0,74***	1,27	1,33
DLIPI	**-10,40*****	**-10,41*****	**0,09**	**-10,12*****	**-10,07*****	**0,33**	**-9,90*****	**-9,86*****
LREER	-1,47	-0,91	0,22***	-2,37	-2,83	0,89***	-0,72	-0,61
DLREER	**-8,12*****	**-8,11*****	**0,08**	**-7,81*****	**-7,79*****	**0,31**	**-7,81*****	**-7,79*****

*,**,*** indicira statistički značajan rezultat na razini od, redom; 10%, 5%, 1%.
Izvor: Izračun autorice

Kako su sve varijable kojima se konstruira VAR model s realnom cijenom nafte (DLOIL, DLBDP, DLIPI i DLREER) integrirane reda jedan (I(1)), nužno je ispitati i eventualno postojanje kointegracije među promatranim varijablama. Isto je učinjeno korištenjem Johansenovog testa kointegracije čiji su rezultati prikazani Tablicom 4.4.1.2. Dok test traga matrice svojstvenih vrijednosti upućuje na postojanje jednog kointegracijskog vektora među varijablama, test najveće svojstvene vrijednosti nije detektirao postojanje kointegracije. Uzimajući u obzir navedene rezultate Johansenovog testa, kao i ranije iznesene zaključke *Naka i Tufte (1997), Engle i Yoo (1987), Clemens i Hendry (1995), Lin i Tsay (1996)* i *Hoffman i Rasche (1996)* koji impliciraju superiornost VAR modela bez *a priori* ograničenja u odnosu na

VECM u kratkom roku, analiza modela se nastavlja uz pretpostavku nepostojanja problema kointegracije[174].

Tablica 4.4.1.2.: Rezultati Johansenovog testa kointegracije za VAR sustav jednadžbi (varijable: LBDP, LIPI, LREER, LOIL)

Test traga matrice

H_0: r =	Svojstvena vrijednost	Test veličina	Kritična vrijednost 0,05	Vjerojatnost**
0 *	0.267175	49.12712	47.85613	0.0378
1	0.181574	23.94837	29.79707	0.2026

* označava odbacivanje nulte hipoteze pri razini od 5% značajnosti
**p vrijednosti prema MacKinnon-Haug-Michelis (1999)

Test najveće svojstvene vrijednosti

H_0: r =	Svojstvena vrijednost	Test veličina	Kritična vrijednost 0,05	Vjerojatnost**
0	0.267175	25.17875	27.58434	0.0985
1	0.181574	16.23015	21.13162	0.2117

* označava odbacivanje nulte hipoteze pri razini od 5% značajnosti
**p vrijednosti prema MacKinnon-Haug-Michelis (1999)

Izvor: Izračun autorice

Slijedi provjera postavljene hipoteze H_1 na način da se procjenjuju 4 VAR sustava jednadžbi ovisno o tome koji je pokazatelj cijene nafte korišten. Svi sustavi obuhvaćaju varijable realnog BDP-a, indeksa industrijske proizvodnje i realnog efektivnog deviznog tečaja (kao i dihotomnu dummy varijablu KRIZA) dok se u sustav redom permutiraju prethodno elaborirani pokazatelji cijena nafte: 1) realna cijena nafte (točnije prva diferencija prirodnog logaritma iste), 2) MORK+ i MORK-, 3) SOPI i SOPD i 4) NOPI4. Način na koji se operacionaliziraju pokazatelji MORK+ i MORK-, kao i SOPI i SOPD, omogućuje njihovo istovremeno uključivanje u VAR sustav jer u vremenskim periodima u kojima MORK+ (ili SOPI) ima neku pozitivnu vrijednost, MORK- (ili SOPD) ima vrijednost nula. Vrijedi i obratno; u vremenskim periodima u kojima MORK- (ili SOPD) ima neku negativnu vrijednost, MORK+ (ili SOPI) ima vrijednost nula.

Nakon što su ispitana stohastička svojstva vremenskih nizova, u sljedećem koraku procjenjuje se optimalan broj vremenskih odmaka koji posljedično utječe i na broj parametara koje je

[174] *Naka i Tufte (1997)* su proučavali performanse inovacijske analize VECM i VAR modela te zaključili kako su rezultati kod analize kraćih vremenskih nizova, kao što je slučaj kod ovog istraživanja, gotovo identični. Navedeno sugerira VAR metodologiju kao optimalan izbor u izvođenju ekonometrijske procjene.

potrebno procijeniti (veći broj odmaka => veći broj parametara). Optimalna duljina pomaka određuje se minimiziranjem informacijskih kriterija pa je temeljem provedenog testa, čiji su rezultati prikazani Tablicom 4.4.1.3, moguće zaključiti da je (prema LR, FPE i AIC kriterijima) optimalna duljina pomaka u dotičnom VAR sustavu jednadžbi (pokazatelj cijena nafte => realna cijena nafte) *k = 6*.

Tablica 4.4.1.3.: Testiranje optimalnog broja vremenskih odmaka (k) u modelu

Vremenski odmak	LogL	LR	FPE	AIC	SC
0	644.0682	NA	6.32e-13	-16.73864	**-16.49330***
1	666.1107	40.60445	5.40e-13	-16.89765	-16.16163
2	682.4433	28.36726	5.38e-13	-16.90640	-15.67970
3	701.5935	31.24501	5.00e-13	-16.98930	-15.27192
4	711.0443	14.42492	6.06e-13	-16.81696	-14.60889
5	732.5835	30.60840	5.41e-13	-16.96272	-14.26398
6	**757.6291**	**32.95473***	**4.47e-13***	**-17.20077***	-14.01134

* Označava optimalan broj vremenskih odmaka prema pojedinom informacijskom kriteriju
Izvor: Izračun autorice

Unatoč postojanju testova kojima se utvrđuje optimalan broj vremenskih odmaka, primarno je procijeniti model koji pokazuje dobre dijagnostičke karakteristike, jer jedino takvi modeli daju pouzdane procjene parametara. Nakon procjene VAR modela sa 6 vremenskih odmaka, pokazalo se da procijenjeni model pokazuje postojanje ozbiljnog problema autokorelacije (za vremenske odmake *k=5* i *k=3*) reziduala zbog čega je u konačnici procijenjen model s 2 vremenska odmaka kod kojeg je navedeni problem (uz razinu signifikantnosti od 5%) anuliran[175] (Tablica 4.4.1.4.).

Tablica 4.4.1.4.: LM test autokorelacije u VAR modelu

Vremenski odmak	LM-Statistika	Vjerojatnost
1	**22.01774**	**0.1426**
2	**23.83706**	**0.0931**

Izvor: Izračun autorice

Također je generirana matrica koeficijenata korelacije unutar koje, izuzev dijagonalnih vrijednosti, niti jedan prikazani koeficijent (u apsolutnom iznosu) ne smije biti veći od 0,5. Ista za VAR model s realnom cijenom nafte je prikazana u nastavku (Tablica 4.4.1.5.) pri čemu

[175] LM statistika ukazuje na prihvaćanje nulte hipoteze za odmake 1 i 2 uz p vrijednost od 14,26%, odnosno 9,31%

rezultati iste zadovoljavaju prethodno definirane kriterije i potvrđuju nepostojanje problema autokorelacije reziduala.

S ciljem daljnje potvrde odabrane duljine odmaka provodi se i Wald test o opravdanosti isključivanja pomaka *k = 1, 2* pri čemu rezultati navedenog testa, prikazani Tablicom 4.4.1.6., potvrđuju prethodni zaključak.

Tablica 4.4.1.5.: Matrica koeficijenata korelacije reziduala

	D(LIPI)	D(LBDP)	D(LREER)	D(LOIL)
D(LIPI)	**1.000000**	0.480565	-0.247204	-0.068019
D(LBDP)	0.480565	**1.000000**	-0.068955	-0.024149
D(LREER)	-0.247204	-0.068955	**1.000000**	-0.120808
D(LOIL)	-0.068019	-0.024149	-0.120808	**1.000000**

Izvor: Izračun autorice

Podaci u posljednjem stupcu tablice su *p* vrijednosti odbacivanja nulte hipoteze koje svojim veličinama (manje od 1%) opravdavaju uključivanje dva vremenska odmaka (*k = 2*) u VAR model.

Ista procedura određivanja optimalnog broja vremenskih odmaka izvršena je za sva 4 VAR sustava jednadžbi, ovisno o korištenim pokazateljima cijena nafte.

Tablica 4.4.1.6.: Wald test o isključivanju vremenskog odmaka iz VAR modela

hi-kvadrat test statistika za isključivanje vremenskog odmaka					
Vremenski odmak	D(LIPI)	D(LBDP)	D(LREER)	D(LOIL)	Zbirno*
1	14.19835 [0.006688]	21.02833 [0.000313]	10.69034 [0.030274]	9.612923 [0.047478]	57.94855 **[1.16e-06]**
2	5.006460 [0.286635]	7.540084 [0.109955]	9.019959 [0.060603]	8.601994 [0.071855]	37.29425 **[0.001906]**
Stupnjevi slobode:	4	4	4	4	16

*Brojevi u uglatim zagradama predstavljaju *p* vrijednosti
Izvor: Izračun autorice

Tablica 4.4.1.7. prikazuje konačan broj odabranih vremenskih odmaka u procijenjenim VAR modelima. Iako su u pojedinim VAR sustavima, kao što je i prethodno bio slučaj u VAR sustavu koji koristi realnu cijenu nafte (DLOIL), korišteni informacijski kriteriji upućivali na odabir većeg broja vremenskih odmaka, problem autokorelacije koji se u tom slučaju pojavljivao

rezultirao je smanjenjem broja korištenih vremenskih odmaka. Tako je kod svih procijenjenih VAR sustava, smanjivanjem broja vremenskih odmaka, anuliran problem autokorelacije.

Tablica 4.4.1.7.: Konačan broj vremenskih odmaka u procijenjenim VAR modelima

Pokazatelj cijena nafte	DLOIL	MORK+/MORK-	SOPI/SOPD	NOPI4
Broj vremenskih odmaka procijenjenog VAR sustava (*k*)	2	2	1	2

Izvor: Izračun autorice

Nakon odabira optimalne duljine odmaka slijedi provjera pretpostavki modela, prvenstveno spomenuta provjera postojanja problema autokorelacije, a potom i problema heteroskedastičnosti kao i provjera oblika distribucije reziduala.

Tablicom 4.4.1.4. prikazani su rezultati LM testa autokorelacije u pojedinom vremenskom odmaku (za VAR sustav s realnom cijenom nafte) gdje su u posljednjem stupcu vjerojatnosti odbacivanja nulte hipoteze o nepostojanju serijske korelacije unutar pojedinog vremenskog odmaka. Podaci unutar tablice ukazuju da za navedene odmake problem autokorelacije reziduala, na razini signifikantnosti od 5%, ne postoji.

U sljedećem koraku provjerava se postojanje problema heteroskedastičnosti reziduala VAR sustava *White testom (White, 1980),* odnosno temeljem dobivenih *p* vrijednosti *hi* kvadrat distribucije (podebljane vrijednosti unutar Tablice 4.4.1.8.). White test ispituje istinitost nulte hipoteze da ne postoji problem heteroskedastičnosti, prema alternativnoj hipotezi da postoji neki tip heteroskedastičnosti reziduala. Rezultati provedenog testa upućuju na zaključak da uz 1% signifikantnosti nema problema heteroskedastičnosti.

Tablica 4.4.1.8.: Test heteroskedastičnosti reziduala u VAR modelu

Joint test:

Hi-kvadrat stat.	df	Vjerojatnost
207.5932	170	0.0261

Izvor: Izračun autorice

Slijedi provjera oblika distribucije reziduala u skladu s rezultatima testa normalnosti prikazanima unutar Tablice 4.4.1.9. U dnu tablice nalazi se podatak o Jarque-Bera test veličini koja uspoređuje podatke o spljoštenosti i (a)simetriji distribucije reziduala s referentnim

vrijednostima za normalno distribuirane reziduale te upućuje odbacivanje pretpostavke o normalnoj distribuciji reziduala.

Tablica 4.4.1.9.: Test normalnosti reziduala

Komponenta	Jarque-Bera	df	Vjerojatnost
1	1.859697	2	0.3946
2	851.6463	2	0.0000
3	3.009680	2	0.2221
4	71.85782	2	0.0000
Zbirno	928.3735	8	**0.0000**

Izvor: Izračun autorice

Distribucija realnih (i nominalnih) ekonomskih pojava (i njihovih reziduala) nerijetko, točnije jako često, odstupa od oblika normalne distribucije. Do ovog problema (između ostalog) često dolazi zbog strukturnih prekida u vremenskim nizovima, što se najčešće rješava ubacivanjem dummy varijable u model. Kako je u svim modelskim specifikacijama prisutna i dummy varijabla (KRIZA), procjene temeljem istih bi trebale biti nepristrane. Također, testovi koji se provode temeljem procijenjenih modela (posebice Waldov test) ne uvjetuju normalnu distribuciju reziduala. Važno je ustvrditi da je model stabilan (analizom stabilnosti modela) te da je, prvenstveno, problem autokorelacije, a potom i problem heteroskedastičnosti anuliran ili, u najgorem slučaju, sveden na prihvatljivu razinu. O tome se, bez iznimke, vodilo računa prilikom procjene svih modela u empirijskom dijelu istraživanja.

Analiza stabilnosti VAR modela (prikazana Grafikonom 4.4.1.1.) implicira da se niti jedan korijen karakteristične jednadžbe ne nalazi izvan jediničnog kruga (po Euklidovoj normi) čime je uvjet stabilnosti procijenjenog VAR modela zadovoljen.

Navedena se procedura ponavlja za svaki procijenjeni VAR model. Stoga su u daljnjem toku istraživanja, odnosno izlaganja rezultata, detaljne provjere stabilnosti modela, iako provedene (kako bi svi modeli temeljem kojih se generira inovacijska analiza bili adekvatno procijenjeni), izostavljene. Konačne test veličine provedene dijagnostike modela nalaze se u sklopu Priloga 2.

Nakon što je prethodno ustanovljeno da je VAR model stabilan, te da varijable nisu kointegrirane, u sljedećem koraku provodi se test Granger uzročnosti u bivarijantnom i multivarijantnom okruženju. Rezultati testa Granger uzročnosti (prikazani Tablicom 4.4.1.10.)

upućuju na zaključak da indeks industrijske proizvodnje, realni efektivni devizni tečaj i realne cijene nafte zajednički utječu (u Granger smislu) na realni BDP. Također, na razini signifikantnosti 5%, evidentirana je Granger uzročnost u smjeru od realnih cijena nafte ka realnom BDP-u. Pored navedenog, na razini signifikantnosti od 10%, evidentirana je i Granger uzročnost u smjeru od indeksa industrijske proizvodnje ka realnom BDP-u kao i od realnog BDP-a ka realnom efektivnom deviznom tečaju. Na isti je način proveden test Granger uzročnosti i za preostala tri procijenjena VAR sustava jednadžbi. Zbog jednostavnosti prikaza i usporedbe rezultata, statistički značajni rezultati su naznačeni unutar iste tablice (Tablica 4.4.1.10.).

Grafikon 4.4.1.1.: Analiza stabilnosti VAR modela, jedinični krug s korijenima polinoma

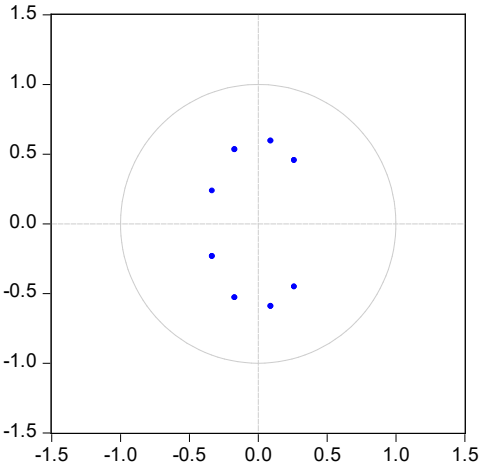

Izvor: Izračun autorice

Kod tri od četiri modela (izuzetak je model s NOPI4) može se uočiti statistički značajna uzročnost u Granger smislu u smjeru od pokazatelja cijena nafte ka realnom BDP-u. Kod MORK+/MORK- VAR modela evidentirana je Granger uzročnost ka realnom BDP-u i kod pozitivnih i kod negativnih promjena cijena nafte, dok je kod modela sa SOPI/SOPD Granger uzročnost evidentirana samo kod SOPD. Potonji rezultat implicira važnost pada cijena nafte u odnosu na kretanje realnog BDP-a u uvjetima volatilnosti, dok, u istim uvjetima, zanemaruje utjecaj rasta cijena nafte (SOPI) na realni BDP. Pored navedenih smjerova uzročnosti, koji su fokus provjere postavljene hipoteze, u svim se modelima također pokazala Granger uzročnost u smjeru od indeksa industrijske proizvodnje ka realnom BDP-u, kao i od realnog BDP-a ka realnom efektivnom deviznom tečaju (uz razinu signifikantnosti od 10%). Konzistentnost ovih rezultata kroz različite VAR modele (točnije VAR modele s različitim pokazateljima cijena nafte) ukazuje na njihovu dobru definiranost kao i na robusnost generiranih rezultata analize.

Tablica 4.4.1.10.: Prikaz statistički značajnih rezultata Granger uzročnosti procijenjenih VAR modela, multivarijantni okvir

VAR model s pokazateljem:	Detektirani smjer Granger uzročnosti
DLOIL	**DLOIL => DLBDP****
	DLIPI => DLBDP*
	DLBDP => DLREER*
MORK+/MORK-	**MORK+ => DLBDP****
	MORK- => DLBDP**
	DLBDP => DLREER*
	DLIPI => DLBDP*
	MORK- => DLIPI*
SOPI/SOPD	**SOPD => DLBDP*****
	SOPD => DLIPI**
	DLBDP => DLREER**
	SOPI => DLREER*
NOPI4	DLIPI => DLBDP*
	DLBDP => DLREER*

*, ** označavaju statistički značajan rezultat uz nivo signifikantnosti od, redoslijedno 10%, 5%.
Izvor: Izračun autorice

Nakon provedene prethodno opisane procedure procjenjuju se istraživanjem definirani VAR sustavi s definiranim varijablama i vremenskim odmacima. Kako je već ranije istaknuto, procijenjeni parametri ne interpretiraju se na uobičajeni način već alatima inovacijske analize temeljem čega se donose zaključci o međusobnim odnosima varijabli u procijenjenom modelu. Zbog navedenog, originalni ispisi i output tablice procijenjenih VAR modela su izuzete iz teksta disertacije jer prikazuju svaku od navedenih varijabli kao endogenu, u zavisnosti o svim ostalim varijablama, ne samo BDP u ovisnosti o cijenama nafte i preostalim odabranim varijablama modela, što je nužno za provjeru postavljene hipoteze. Ipak, prije korištenja navedenih alata provedeno je nekoliko dodatnih testova nad procijenjenim parametrima modela. Jesu li u model uključene primjerene varijable, te utječu li jedna na drugu, ispitano je korištenjem tzv. Wald testa uz pomoć kojeg se postavljaju ograničenja na parametre jednadžbi procijenjenog VAR modela. Procjena uzročnosti temeljem Wald testa provedena je u dva koraka; u bivarijatnom, a potom i u multivarijatnom okruženju. Drugim riječima, prvo se ispituje utječu li vrijednosti pokazatelja cijena nafte na BDP direktno, a potom se ispituje utječu li iste na BDP indirektno kroz ostale varijable u modelu, pri tome uvažavajući mogućnost postojanja i funkcioniranja alternativnih mehanizama transmisije utjecaja cijena nafte na preostale, modelom obuhvaćene, pokazatelje.

Kako bi se ispitalo utječu li cijene nafte na BDP neposredno testirane su sljedeće hipoteze:

H_0: Koeficijenti pokazatelja cijena nafte su jednaki nuli u jednadžbi BDP-a promatranog VAR sustava jednadžbi.

H_1: Koeficijenti pokazatelja cijena nafte nisu jednaki nuli u jednadžbi BDP-a promatranog VAR sustava jednadžbi.

Rezultati su prikazani unutar Tablice 4.4.1.11. gdje su istaknute *p* vrijednosti hi kvadrat distribucije za provedeni test.

Tablica 4.4.1.11.: Rezultati Wald testa – bivarijantni okvir

DLOIL	MORK+	MORK-	SOPI	SOPD	NOPI4
0,0154**[176]	**0,0001*****	**0,0000*****	0,1613	**0,0002*****	0,2626

p vrijednosti hi kvadrat distribucije. Podebljane vrijednosti unutar ćelija označavaju statistički značajan rezultat na razini od 1%, 5% ili 10%, redoslijedno: ***,**,*.
Izvor: Izračun autorice

Rezultati provedenih Wald testova nad procijenjenim parametrima VAR sustava impliciraju odbacivanje H_0 u BDP jednadžbi procijenjenih VAR sustava kod pokazatelja cijena nafte DLOIL, MORK+, MORK- i SOPD, odnosno da navedeni pokazatelji statistički značajno utječu na BDP. Pri tome je utjecaj DLOIL na realni BDP statistički značajan na razini od 5%, a kod preostalih pokazatelja nafte na razini od 1%. Zanimljivo je istaknuti da je kod SOPI/SOPD pokazatelja nafte statistički značajan utjecaj cijena nafte na BDP u situaciji pada cijena nafte (SOPD), a ne rasta, kako bi bilo za očekivati temeljem postojećih teorijskih spoznaja. Navedeni rezultati potvrđuju i prethodno provedenu analizu Granger uzročnosti.

Kako bi se procijenilo utječu li možda cijene nafte na realni BDP posredno putem preostalih odabranih varijabli u modelu (indeksa industrijske proizvodnje i realnog efektivnog deviznog tečaja), testira se statistička značajnost varijable cijene nafte za cjelokupan VAR sustav (odnosno za procijenjene jednadžbe VAR sustava bez jednadžbe pokazatelja cijene nafte i BDP-a). Stoga su u sljedećem koraku Wald testom su testirane sljedeće hipoteze:

H_0: Koeficijenti pokazatelja cijena nafte su jednaki nuli u svim jednadžbama procijenjenog VAR sustava osim u jednadžbi cijene nafte i BDP jednadžbi.
H_1: Koeficijenti pokazatelja cijena nafte nisu jednaki nuli u svim jednadžbama procijenjenog VAR sustava osim u jednadžbi cijene nafte i BDP jednadžbi.

[176] p vrijednosti hi-kvadrat distribucije za odabrane modele

Rezultati Wald testa, prikazani Tablicom 4.4.1.12. pokazuju statistički značajan utjecaj cijena nafte na preostale varijable u VAR sustavu samo kod MORK- (na razini od 10% signifikantnosti) i SOPD pokazatelja.

Tablica 4.4.1.12.: Rezultati Wald testa – multivarijantni okvir

DLOIL	MORK+	MORK-	SOPI	SOPD	NOPI4
0,2512	0,6571	**0,0863***	0,1593	**0,0479****	0,4459

p vrijednosti hi kvadrat distribucije. Podebljane vrijednosti unutar ćelija označavaju statistički značajan rezultat na razini od 1%, 5% ili 10%, redoslijedno: ***,**,*.
Izvor: Izračun autorice

Kombiniranjem navedenih rezultata s onima iz prethodne tablice može se konstatirati da je utjecaj cijena nafte na realni BDP neposredan, odnosno da se posredno odvija putem preostalih varijabli uključenih u procjenu VAR sustava samo u slučaju pada cijena nafte. Uslijed rasta cijena nafte koeficijenti pokazatelja cijena nafte u jednadžbama procijenjenog VAR sustava nisu statistički značajni. To znači da ako uslijed rasta cijena nafte i postoji indirektan utjecaj cijena nafte na realnu gospodarsku aktivnost predstavljenu BDP-om, on se ne prenosi na BDP putem odabranih varijabli (DLIPI i DLREER).

U daljnjoj analizi proveden je još jedan Wald test kako bi se ispitalo jesu li pozitivni i negativni koeficijenti pokazatelja cijena nafte jednaki u svim jednadžbama procijenjenih VAR modela. Cilj ove analize je ustanoviti postoji li statistički značajna razlika u visini procijenjenih koeficijenata ovisno o tome odnosi li se odabrani pokazatelj na povećanja ili smanjenja cijena nafte. Kako se može iščitati iz Tablice 4.4.1.13. koja prezentira rezultate, analiza je obuhvatila samo one pokazatelje koji se raščlanjuju na pozitivne i negativne promjene cijene nafte (dakle, realna cijena nafte i NOPI4 nisu uključeni u analizu). Podaci u tablici su prikazani svjetlijom bojom ako pripadajući pokazatelj cijene nafte nije bio u prethodnoj analizi statistički značajan unutar BDP jednadžbe odnosno cjelokupnog VAR modela. U protivnom, ako su isti prethodno dokazani kao statistički značajni, rezultati testa su unutar tablice podebljani.

Tablica 4.2.1.13.: Rezultati Wald testa jednakosti procijenjenih parametara pokazatelja pozitivnih i negativnih promjena cijena nafte

MORK+ = MORK-		SOPI = SOPD	
BDP jednadžba	VAR sustav jednadžbi	BDP jednadžba	VAR sustav jednadžbi
0,0000***	0,2971	**0,0002*****	**0,0789***

p vrijednosti hi kvadrat distribucije. Podebljane vrijednosti unutar ćelija označavaju statistički značajan rezultat na razini od 1%, 5% ili 10%, redoslijedno: ***,**,*.
Izvor: Izračun autorice

Rezultati Wald testa indiciraju prihvaćanje, odnosno odbacivanje postavljenih hipoteza:

H_0: Pozitivni i negativni koeficijenti pokazatelja cijena nafte su jednaki u jednadžbi BDP-a odnosno u ostalim jednadžbama promatranog VAR sustava.
H_1: Pozitivni i negativni koeficijenti pokazatelja cijena nafte nisu jednaki u jednadžbi BDP-a odnosno u ostalim jednadžbama promatranog VAR sustava.

U skladu s rezultatima Wald testa može se zaključiti da su unutar BDP jednadžbe procijenjenog VAR sustava pozitivni i negativni koeficijenti pokazatelja cijena nafte MORK+/MORK- i SOPI/SOPD statistički značajno različiti i to uz nivo pouzdanosti 1%. S druge strane, pozitivni i negativni koeficijenti pokazatelja cijena nafte MORK+/MORK- u preostalim jednadžbama VAR sustava nisu statistički značajno različiti, odnosno kod SOPI/SOPD pokazatelja može se konstatirati da je njihova razlika statistički značajna na razini od 10%. Ovakvi rezultati upućuju na asimetričan utjecaj cijena nafte na BDP implicirajući statistički značajnu razliku u veličini procijenjenih parametara pozitivnih i negativnih promjena cijena nafte. Iako rezultati ne ukazuju na smjer i intenzitet odnosa cijena nafte i realnog gospodarstva, ključni su kako bi se u daljnjoj analizi opravdano odvojeno promatrali i uvrštavali pokazatelji cijena nafte koji pokazuju povećanja, odnosno smanjenja cijena nafte.

Prije inovacijske analize nužno je prikazati i značajnost dummy varijable *KRIZA*, što je također provjereno Wald testom na način da se ispitalo jesu li koeficijenti ispred navedene varijable statistički značajno različiti od nule. Rezultati Wald testa (Tablica 4.4.1.14.) upućuju na zaključak da je, neovisno o korištenom pokazatelju cijena nafte, utjecaj krize na realni BDP negativan (što implicira predznak procijenjenih koeficijenata) i statistički značajan na razini od 1%. Istovjetan je utjecaj dummy varijable KRIZA i na varijablu indeksa industrijske proizvodnje, dok utjecaj krize na realni efektivni devizni tečaj nije statistički značajan.

Konačno, završni dio analize podrazumijeva korištenje alata inovacijske analize. Dok funkcije impulsnog odaziva ukazuju na smjer i intenzitet utjecaja naftnog šoka na preostale varijable u modelu (po tromjesečjima), dekompozicija varijance analizira u kojoj je mjeri promjenjivost cijena nafte odgovorna za promjenjivost ostalih varijabli u modelu.

Tablica 4.4.1.14.: Statistička značajnost dummy varijable KRIZA

Model s pokazateljem:	Utjecaj varijable KRIZA na:	Vrijednost procijenjenog parametra:
DLOIL	**DLBDP**	**-0,021500*** **
	DLIPI	**-0,025541*** **
	DLREER	0,003056
MORK+/MORK-	**DLBDP**	**-0,024960** **
	DLIPI	**-0,028109*** **
	DLREER	0,003219
SOPI/SOPD	**DLBDP**	**-0,021658*** **
	DLIPI	**-0,026473*** **
	DLREER	0,001723
NOPI4	**DLBDP**	**-0,020122*** **
	DLIPI	**-0,024289*** **
	DLREER	0,004445

*,**,*** indicira statistički značajan rezultat na razini od, redom; 10%, 5%, 1%.
Izvor: Izračun autorice

Grafikonom 4.4.1.2. prikazane su funkcije impulsnog odziva varijable DLBDP pri čemu je šok u sustavu jednadžbi definiran kao promjena u visini jedne standardne devijacije varijable pokazatelja cijene nafte (DLOIL, MORK+/MORK-, SOPI/SOPD, NOPI4). Pune linije predstavljaju impulsne funkcije odziva, a isprekidane linije odstupanje od dvije standardne devijacije (riječ je stoga o intervalima pouzdanosti od 95%). Na ordinati su razine pojave izražene u mjernim jedinicama varijable, a na apscisi vrijeme izraženo u tromjesečjima. Općenito kad je utjecaj nezavisne varijable na zavisnu (u ovom slučaju realni BDP) statistički značajan, bilo pozitivan ili negativan, sama se funkcija odziva, uključujući i prezentirana odstupanja od iste, nalazi iznad (ako je utjecaj pozitivan) odnosno ispod (ako je utjecaj negativan) nulte horizontalne linije na grafikonu (predstavljene punom crnom linijom). Iskazivanje funkcija impulsnog odziva bez odstupanja bilo bi kao prezentiranje procijenjenih parametara bez t vrijednosti kojima bi se potvrdila njihova statistička značajnost. Stoga, ako prikazana funkcija zajedno sa zadanim granicama od ± 2 standardne devijacije (SD) siječe horizontalnu liniju grafikona, utjecaj promatrane varijable na DLBDP u promatranom vremenskom periodu nije statistički značajan (*Berument i Ceylan, 2010*). Također, poželjno je da je standardna devijacija što manja, odnosno da su granice +/- 2 SD što uže u odnosu na procijenjenu funkciju impulsnog odziva (plavu liniju).

Grafikon 4.4.1.2.: Impulsne funkcije odziva varijable DLBDP na šok od jedne standardne devijacije u varijablama koje predstavljaju pokazatelje cijena nafte u svim procijenjenim VAR modelima

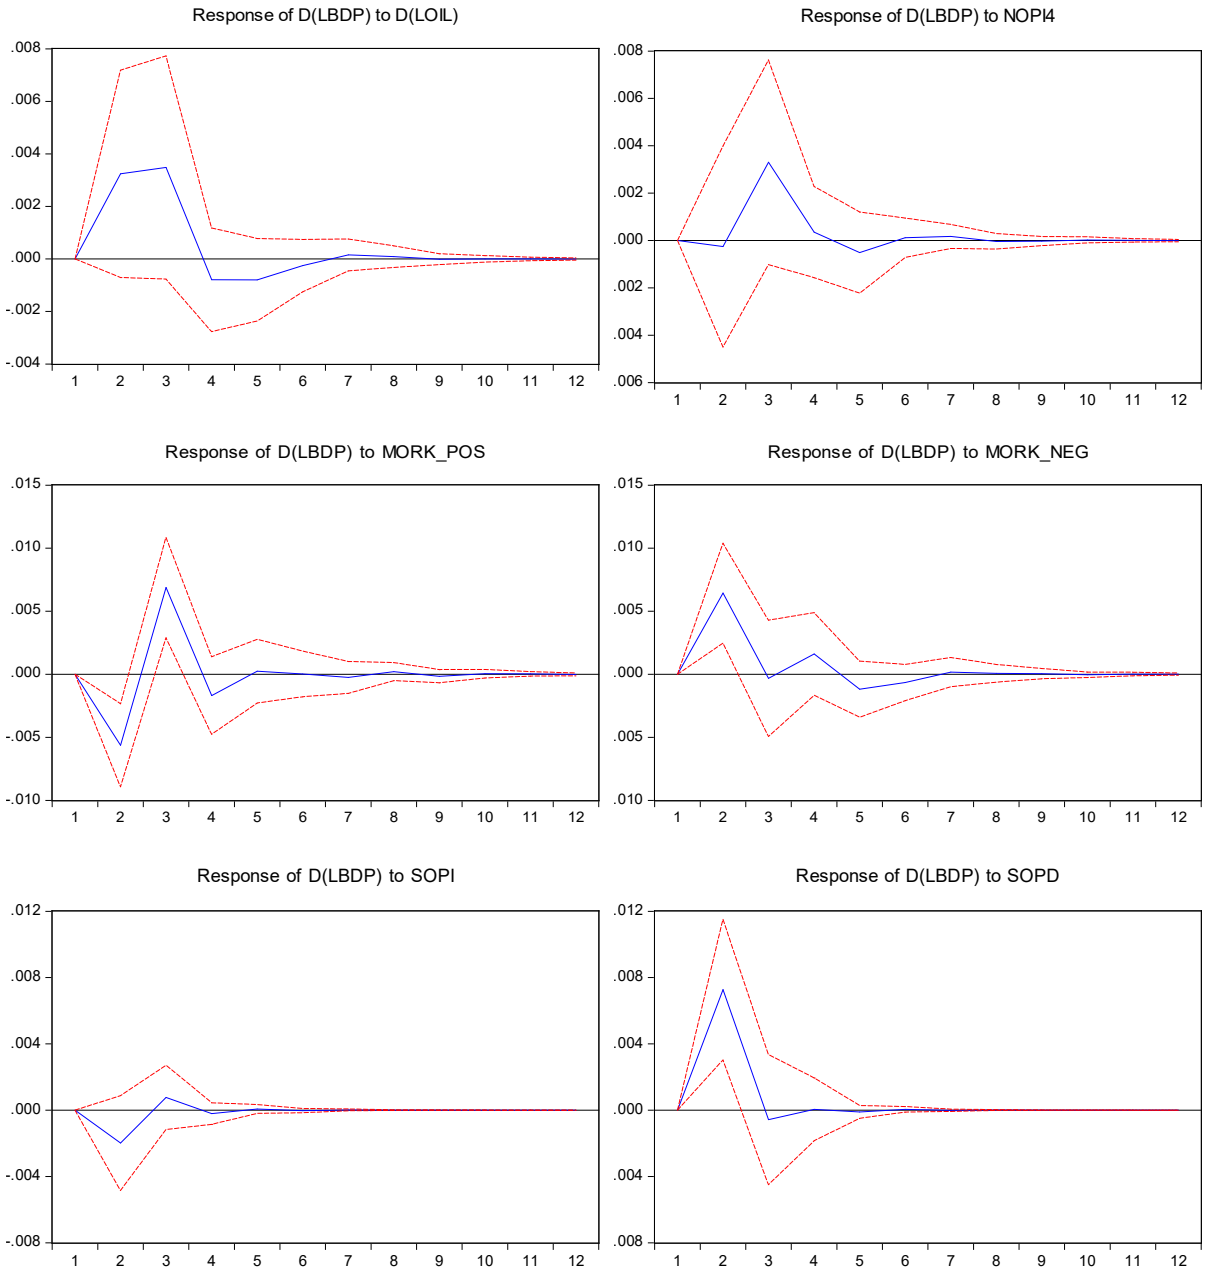

*Pune plave linije predstavljaju funkcije, isprekidane crvene linije odstupanje od dvije standardne devijacije (interval pouzdanosti procjene 95%), na ordinati su razine pojave izražene u mjernim jedinicama varijable, a na apscisi vrijeme izraženo u tromjesečjima.
Izvor: Izračun autorice

Sagledavanjem reakcije BDP-a na naftni šok, nužno je, za početak eliminirati one čiji utjecaj na realni BDP nije statistički značajan, a to su SOPI i NOPI4, na što ukazuju i rezultati Granger testa uzročnosti. Funkcije impulsnog odziva varijable DLBDP na šok u varijabli koja predstavlja cijene nafte također impliciraju kako je reakcija DLBDP na realne cijene nafte (DLOIL) u prva dva tromjesečja pozitivna, iako statistički značajna tek na razini od 10%

signifikantnosti). Reakcija DLBDP-a na MORK- i SOPD pokazatelje, koji prikazuju pad cijena nafte, je vrlo slična: pozitivna i statistički značajna u prva dva, odnosno tri tromjesečja, nakon čega više nije statistički značajna. MORK+, s druge strane, u prva dva tromjesečja utječe na negativnu statistički značajnu reakciju DLBDP, koja nakon toga u trećem tromjesečju prelazi u pozitivnu, a od četvrtog tromjesečja nadalje više nije statistički značajna. Također se može konstatirati da protokom, najdalje, konca druge godine (osmog tromjesečja) utjecaj cijena nafte na DLBDP u potpunosti iščezava (neovisno o korištenom pokazatelju cijena nafte).

Podaci u Tablici 4.4.1.15. prikazuju rezultate dekompozicije varijance prognostičke greške za procijenjene BDP jednadžbe VAR modela s realnom cijenom nafte za period od dvije godine (8 tromjesečja) i to na način da je ista razložena na doprinos pojedine varijable u sustavu ukupnoj varijanci prognostičke greške varijable realnog BDP-a (zbroj rezultata u retku je 100%, s izuzetkom prvog stupca koji prikazuje standardnu grešku – S.E.). Uobičajeno je da rezultati dekompozicije varijance za varijable pokazuju kako protekom definiranog vremenskog perioda same varijable objašnjavaju veći dio varijance vlastite prognostičke pogreške, kao i da se taj dio s protekom vremena smanjuje i stabilizira. Ako se vrijednosti varijable mogu adekvatno prognozirati na bazi vremenskih pomaka same varijable, tada će varijanca prognostičke pogreške varijable biti "objašnjena" prognostičkim pogreškama same varijable, a ne i utjecajem prognostičkih pogrešaka ostalih varijabli (*Sims, 1982*). U protivnom, kroz dekompoziciju varijance moguće je sagledati utjecaj preostalih varijabli u sustavu na varijabilnost promatrane varijable. Konkretnije, ovdje je svakako fokus na objašnjenju varijabilnosti realnog BDP-a varijabilnošću cijena nafte.

Tablica 4.4.1.15.: Dekompozicija varijance varijable realni BDP (DLBDP)

Period	S.E.	D(LBDP)	D(LIP)	D(LREER)	**D(LNOIL)**
1	0.017505	100.0000	0.000000	0.000000	**0.000000**
2	0.019648	96.48182	0.487447	0.311097	**2.719637**
3	0.020184	91.69080	0.886154	1.869904	**5.553140**
4	0.020328	90.50381	2.013055	1.856135	**5.626997**
8	0.020370	90.17174	2.187447	1.861042	**5.779776**

Cholesky poredak varijabli: D(LBDP) D(LIP) D(LREER) D(LNOIL)[177]

Izvor: Izračun autorice

[177] Poredak Choleskog (*engl. Cholesky ordering*) može utjecati na finalni izgled IRF i DV, pri čemu, ako je n broj varijabli postoji n! različitih kombinacija odnosno mogućih poredaka istih. Kod svih su se modela testirali i alternativni poredci varijabli, no isti nisu polučili značajno različite rezultate u odnosu na prikazane.

Dekompozicija varijance varijable realnog BDP-a pokazuje da je najveći dio varijacija analizirane varijable kroz vrijeme moguće objasniti samom varijablom realnog BDP-a (od 100% početkom promatranog perioda do 90% koncem promatranog perioda), pri čemu se stabilizacija varijance može uočiti od 4 tromjesečja na dalje (zbog čega su dekompozicije za periode 5, 6, i 7 izuzete). Na varijablu realnog BDP-a od preostalih varijabli, iako skroman, najveći utjecaj ima varijabla realnih cijena nafte čije kretanje može pojasniti nešto manje od 6% varijance prognostičke greške BDP-a. Navedeni udio nije pretjerano značajan, ali je ipak viši u odnosu na ostale varijable u sustavu, indeks industrijske proizvodnje i realni efektivni devizni tečaj.

Iako je dekompozicija varijance napravljena u svim procijenjenim VAR sustavima, ovdje je prikazana dekompozicija varijance samo za varijablu DLBDP (može se prikazati za sve varijable u modelu) i to u modelima u kojima se prethodnom analizom ustanovio statistički značajan utjecaj dotičnog pokazatelja na realni BDP. Navedeno, pored DLOIL pokazatelja obuhvaća MORK+/MORK- i SOPI/SOPD. Podaci o dekompoziciji varijance (u Tablici 4.4.1.16.) pokazuju da asimetrični pokazatelji cijena nafte pojašnjavaju veći dio varijance varijable DLBDP.

Tablica 4.4.1.16.: Dekompozicije varijance varijable DLBDP

Dekompozicije varijance varijable D(LBDP):						
Period	S.E.	D(LBDP)	D(LIPI)	D(LREER)	**MORK_NEG**	**MORK_POS**
1	0.015338	76.35916	23.50790	0.132943	0.000000	0.000000
2	0.018691	61.37076	16.25287	1.427836	11.86787	9.080660
3	0.020108	53.18161	14.74909	2.237161	10.27874	19.55339
4	0.020262	52.53704	14.52656	2.230318	10.75780	19.94828
8	0.020669	50.51291	17.29037	2.211366	10.77642	19.20894
Cholesky poredak varijabli: D(LREER) D(LIPI) D(LBDP) MORK_NEG MORK_POS						
Dekompozicije varijance varijable D(LBDP):						
Period	S.E.	D(LBDP)	D(LIPI)	D(LREER)	**SOPD**	**SOPI**
1	0.017343	100.0000	0.000000	0.000000	0.000000	0.000000
2	0.020231	85.65687	0.330509	0.127687	12.92641	0.958526
3	0.020355	85.54429	0.379675	0.138782	12.84693	1.090329
4	0.020371	85.54184	0.389325	0.141920	12.82762	1.099295
8	0.020374	85.53987	0.390073	0.142104	12.82754	1.100413
Cholesky poredak varijabli: D(LREER) D(LIPI) D(LBDP) SOPD SOPI						

Izvor: Izračun autorice

Konkretno, taj se udio kod MORK- pokazatelja kreće na razini od oko 10%, a kod pokazatelja MORK+ čak i do 20% varijance varijable DLBDP. Drugim riječima, ova dva pokazatelja cijena nafte zbirno pokrivaju čak trećinu dekompozicije varijance varijable DLBDP i to već u trećem tromjesečju nakon šoka. Kod SOPI/SOPD pokazatelja, SOPI pojašnjava gotovo neznatan dio varijance dok, istovremeno, na SOPD „otpada“ gotovo 13% varijance varijable DLBDP. Ono što je također važno istaknuti je da se udjeli unutar dekompozicije varijance relativno brzo stabiliziraju. Od trećeg tromjesečja nadalje njihove su promjene minorne, što odgovara i prethodno provedenoj analizi funkcija impulsnog odziva. Evidentno je da kod modela s MORK+/MORK- i SOPI/SOPD pokazateljima cijene nafte objašnjavaju varijancu prognostičke greške varijable DLBDP u rasponu do 20% što *potvrđuje ovisnost kretanja BDP-a o kretanjima cijena nafte*. Ako se izuzme udio varijance vlastite prognostičke pogreške, kod sva tri prikazana VAR modela cijene nafte su primarni izvor varijabilnosti varijable BDP-a (među preostalim odabranim varijablama modela).

S obzirom da su izuzev pokazatelja cijena nafte preostale varijable u modelu jednake (DLBDP, DLIPI, DLREER), kako bi se odgovorilo na pitanje koji je pokazatelj cijene nafte primjereniji, uspoređeni su korigirani koeficijenti determinacije BDP jednadžbi procijenjenih VAR modela (Tablica 4.4.1.17.), a potom i informacijski kriteriji istih (Tablica 4.4.1.18.). Cilj je definirati jednadžbu s višim koeficijentom determinacije, odnosno nižim vrijednostima informacijskih kriterija. Rezultati prikazani u obje tablice upućuju na zaključak o korištenju MORK+/MORK- asimetričnog pokazatelja cijene nafte kao najprimjerenijeg u analizi utjecaja cijena nafte na realni BDP.

Tablica 4.4.1.17.: Korigirani koeficijenti determinacije BDP jednadžbi procijenjenih VAR sustava

Model s pokazateljem:	$\bar{R}^2$
LOIL	0.265589
MORK+/MORK-	**0.436110**
SOPI/SOPD	0.307465
NOPI4	0.209487

Izvor: Izračun autorice

U konačnici, temeljem provedene analize može se konstatirati da je najprimjereniji pokazatelj cijene nafte u ovom slučaju MORK+, odnosno MORK-, pri čemu je analiza modela korištenjem navedenih pokazatelja ukazala na činjenicu da promjene cijena nafte statistički značajno utječu na realni BDP pri čemu je reakcija BDP-a različita ovisno o toma rastu li cijene nafte ili padaju. Konkretno, rast cijena nafte, iskazan pokazateljem MORK+, u prva dva tromjesečja nakon

promjene, ima negativan utjecaj na realni BDP, koji nakon toga prelazi u pozitivan utjecaj u naredna dva tromjesečja stoga je kumulativni efekt rasta cijena nafte na BDP nakon 4 tromjesečja neutralan. S druge strane, pad cijena nafte ima pozitivan efekt na rast realnog BDP-a s vrhuncem u drugom tromjesečju. Do istih se zaključaka može doći promatrajući i reakciju BDP-a na promjenu SOPD koja je također pozitivna, kao i promatrajući reakciju BDP-a na promjenu realnih cijena nafte (DLOIL) gdje je kumulativni efekt na BDP pozitivan (iako statistički značajan na razini od 10%). Reakcije BDP-a na promjene NOPI4 nisu statistički značajne, a i VAR sustav jednadžbi procijenjen s navedenim pokazateljem cijena nafte je u najmanjoj mjeri reprezentativan u odnosu na preostale procijenjene VAR modele.

Tablica 4.4.1.18.: Vrijednost Akaike (AIC) i Schwarz (SBC) informacijskih kriterija BDP jednadžbi procijenjenih VAR sustava

Model s pokazateljem:	AIC	SBC
LOIL	-5.137551	-4.841940
MORK+/MORK-	**-5.380952**	**-5.026219**
NOPI4	-5.063938	-4.768327
SOPI/SOPD	-5.138006	-4.772738

Izvor: Izračun autorice

Zaključno se može konstatirati da realni BDP različito, odnosno asimetrično, reagira na pozitivne i negativne naftne šokove pri čemu je utjecaj pada cijena nafte na realni BDP pozitivan, a utjecaj rasta cijena nafte na realni BDP inicijalno negativan. Drugim riječima, empirijski rezultati upućuju na **prihvaćanje hipoteze H1**: *Promjene cijena nafte statistički značajno negativno utječu na stopu rasta bruto domaćeg proizvoda hrvatskog gospodarstva.*

4.4.2. Utjecaj cijena nafte na inflaciju

S ciljem empirijske provjere hipoteze *H2: Promjene cijena nafte statistički značajno utječu na inflaciju*, konstruirana su 4 VAR modela općeg oblika (4.4.) kojima su obuhvaćene varijable Zt vektora (za period 1995:M01-2015:M12): *LCPI* - prirodni logaritam indeksa potrošačkih cijena (2010=100), *LM1* - prirodni logaritam monetarnog agregata M1, *IR* - kamatna stopa na prekonoćne kredite, *LNEER* - prirodni logaritam nominalnog efektivnog deviznog tečaja (2010=100), *LIPI* - prirodni logaritam indeksa industrijske proizvodnje (2010=100), *LOILN* - prirodni logaritam nominalne cijene nafte (odnosno pripadajući pokazatelj cijene nafte; *MORK+/MORK-, SOPI/SOPD, NOPI4*), te dummy varijabla *KRIZA*. S obzirom da su korištene varijable, odnosno vrijednosti istih, dostupne na mjesečnoj razini, ovime je omogućeno modeliranje s nešto duljim vremenskim nizovima, od po 252 opservacije po varijabli, što

potencira i bolju ekonometrijsku osnovu za provođenje kvantitativne, a kasnije i kvalitativne, analize.

Inicijalno su provedeni, ranije opisanim procedurama, testovi jediničnog korijena čiji su rezultati, test veličine s naznakom razine statističke značajnosti, sabrani unutar Tablice 4.4.2.1.

Tablica 4.4.2.1.: Rezultati testova jediničnog korijena za korištene vremenske nizove, mjesečni podaci (1995:M01-2015:M12)

	Model s konstantom i trendom			Model s konstantom			Model bez konstante	
	ADF	PP	KPSS	ADF	PP	KPSS	ADF	PP
LOILN	0,88	0,88	0,19**	0,51	0,50	1,77***	0,72	0,74
DLOILN	**-12,79*****	**-12,79*****	**0,09**	**-12,75*****	**-12,75*****	**0,19**	**-12,76*****	**-12,76*****
MORK+	**-15,60*****	**-15,64*****	**0,16****	**-15,42*****	**-15,55*****	**0,44***	**-2,98*****	**-12,96*****
MORK-	**-11,35*****	**-11,33*****	**0,059**	**-11,37*****	**-11,34*****	**0,06**	**-9,08*****	**-9,36*****
SOPI	**-18,03*****	**-18,12*****	**0,17****	**-17,78*****	**-17,78*****	**0,52****	**-2,59*****	**-14,25*****
SOPD	**-13,63*****	**-13,59*****	**0,07**	**-13,66*****	**-13,62*****	**0,06**	**-10,65*****	**-11,57*****
NOPI4	**-12,91*****	**-12,94*****	**0,12***	**-12,85*****	**-12,89*****	**0,22**	**-3,77*****	**-11,76*****
LCPI	-0,22	-0,02	0,32***	-2,79*	-2,78*	2,01***	4,99	7,20
DLCPI	**-11,69*****	**-12,14*****	**0,08**	**-11,21*****	**-11,91*****	**0,67****	**-10,51*****	**-10,74*****
LM1	-1,49	-1,54	0,44***	-3,18**	-2,58*	1,91***	5,99	4,69
DLM1	**-15,85*****	**-16,01*****	**0,09**	**-15,40*****	**-15,79*****	**0,63****	**-3,91*****	**-14,92*****
IR	-3,17*	-3,17*	0,26***	-2,43	-2,57	1,22***	-2,06**	-2,11**
DIR	**-13,37*****	**-15,01*****	**0,03**	**-8,57*****	**-15,03*****	**0,04**	**-8,56*****	**-15,05*****
LNEER	-2,14	-1,75	0,21**	-2,15	-1,75	0,20	0,52	0,67
DLNEER	**-12,37*****	**-12,10*****	**0,11**	**-12,39*****	**-12,13*****	**0,11**	**-12,39*****	**-12,14*****
LIPI	-0,95	-2,61	0,45***	-2,08	-1,95	1,29***	1,67	1,06
DLIPI	**-12,33*****	**-30,23*****	**0,09**	**-12,09*****	**-25,84*****	**0,24**	**-11,92*****	**-25,06*****

Izvor: Izračun autorice

Kod većine odabranih varijabli stacionarnost je postignuta prvom diferencijom vremenskih nizova te su, uz visoke razine pouzdanosti, odbačene nulte hipoteze kod ADF i PP testa, a kod KPSS testa prihvaćene za varijable u razinama i obratno, za logaritmirane varijable u diferencijama. Temeljem navedenog može se zaključiti da su varijable: DLCPI – prva diferencija logaritma indeksa potrošačkih cijena (2010=100), DLM1 - prva diferencija logaritma monetarnog agregata M1[178], DIR - prva diferencija kamatne stope, DLNEER - prva diferencija logaritma nominalnog efektivnog deviznog tečaja (2010=100), DLIPI - prva

[178] Kod varijable DLM1 važno je naznačiti da su testovi jediničnog korijena kod modela s konstantom upućivali na zaključak da je ista I(0). Kad se uzmu u obzir rezultati i ostalih testova, za modele s trendom i konstantom i modele bez konstante, moglo bi se konstatirati i da je dotična varijabla granično stacionarna u razinama. Zbog navedenog je provedeno testiranje modela i uz pretpostavku da je LM1 I(0) pri čemu je u model dodan trend, kao i uz pretpostavku da je LM1 I(1). Kako su analizirani modeli ponudili vrlo slične rezultate (u kvalitativnom i kvantitativnom smislu) ovdje je prikazan samo model koji podrazumijeva da je LM1 I(1).

diferencija logaritma indeksa industrijske proizvodnje (2010=100) i DLOILN - prva diferencija logaritma nominalne cijene nafte, integrirani reda jedan (I(1)), dok su preostali pokazatelji cijena nafte stacionarni u razinama, odnosno integrirani reda nula, I(0) (MORK+, MORK-, SOPI, SOPD i NOPI4). S obzirom da je ovdje odabrana varijabla od interesa CPI stacionarna tek nakon diferenciranja, stacionarni oblik korištene varijable (prva diferencija prirodnog logaritma CPI) je, u stvarnosti, inflacija (stopa rasta CPI). Važno je napomenuti i da je kod svih varijabli ponovno provođena procedura utvrđivanja (ne)postojanja jediničnog korijena (bez obzira što je za dio njih isto rađeno kod provjere H_1) jer su sada korišteni vremenski nizovi više frekvencije.Kako su sve varijable kojima se konstruira VAR model s nominalnom cijenom nafte (DLOILN, DLCPI, DLM1, DIR, DLNEER i DLIPI) integrirane reda jedan (I(1)), nužno je Johansenovim testom ispitati i eventualno postojanje kointegracije među promatranim varijablama. Prethodno je nužno odrediti i optimalan broj vremenskih odmaka u modelu. Provodeći za to primjerene ekonometrijske testove, odabran je i konačan broj vremenskih odmaka. Važno je istaknuti da je kod procijenjenih modela dolazilo do odstupanja finalnog odabira broja vremenskih odmaka u odnosu na broj koji su sugerirali za to predviđeni testovi, a sve s ciljem odabira modela koji ima zadovoljavajuće dijagnostičke karakteristike, odnosno onog koji ne pokazuje postojanje problema autokorelacije reziduala te zadovoljava uvjet stabilnosti. Tablica 4.4.2.2. prikazuje konačan odabir broja vremenskih odmaka, dok je dijagnostika procijenjenih modela prikazana u sklopu Priloga 2.

Tablica 4.4.2.2.: Konačan broj vremenskih odmaka u procijenjenim VAR modelima

Pokazatelj cijena nafte	DLOILN	MORK+/MORK-	SOPI/SOPD	NOPI4
Broj vremenskih odmaka procijenjenog VAR sustava (k)	4	5	4	4

Izvor: Izračun autorice

S izuzetkom modela s MORK+/MORK- pokazateljem cijena nafte, kod kojeg je odabran model s 5 vremenskih odmaka, kod svih je preostalih modela analiza upućivala na modele s 4 vremenska odmaka kao optimalne. S ciljem daljnje potvrde odabrane duljine odmaka proveden je i Wald test o opravdanosti isključivanja pomaka k = 1-5 pri čemu su rezultati navedenog testa potvrđivali rezultate prikazane Tablicom 4.2.2.2. Konačno se temeljem provedene analize može konstatirati da se većina međusobnog utjecaja odabranih varijabli odvija unutar perioda od 4 mjeseca.

Potom je proveden i Johansen test kointegracije čiji su rezultati prikazani Tablicom 4.4.2.3.

Tablica 4.4.2.3.: Rezultati Johansenovog testa kointegracije za VAR sustav jednadžbi (varijable: DLOILN, DLCPI, DLM1, DIR, DLNEER i DLIPI)

Test traga matrice

H_0: r =	Svojstvena vrijednost	Test veličina	Kritična vrijednost 0,05	Vjerojatnost**
0 *	0.143087	101.3553	95.75366	0.0195*
1	0.101991	63.21390	69.81889	0.1502

* označava odbacivanje nulte hipoteze pri razini od 5% značajnosti
**p vrijednosti prema MacKinnon-Haug-Michelis (1999)

Test najveće svojstvene vrijednosti

H_0: r =	Svojstvena vrijednost	Test veličina	Kritična vrijednost 0,05	Vjerojatnost**
0	0.143087	38.14138	40.07757	0.0813
1	0.101991	26.57113	33.87687	0.2870

* označava odbacivanje nulte hipoteze pri razini od 5% značajnosti
**p vrijednosti prema MacKinnon-Haug-Michelis (1999)

Izvor: Izračun autorice

Dok test traga matrice svojstvenih vrijednosti upućuje na postojanje jednog kointegracijskog vektora među varijablama, test najveće svojstvene vrijednosti nije detektirao postojanje kointegracije. Uzimajući u obzir navedene rezultate kao i ranije navedena istraživanja koja ukazuju na superiornost VAR sustava bez *a priori* ograničenja u odnosu na VECM u kratkom roku (*Naka i Tufte, 1997; Engle i Yoo, 1987; Clemens i Hendry, 1995; Lin i Tsay, 1996; Hoffman i Rasche, 1996),* daljnja ekonometrijska analiza nastavlja se uz pretpostavku nepostojanja kointegracije.

Slijedi provjera postavljene hipoteze H2, o utjecaju cijena nafte na inflaciju na način da se procjenjuju 4 VAR sustava jednadžbi ovisno o tome koji je pokazatelj cijene nafte korišten.

Nakon što je prethodno ustanovljen optimalan broj vremenskih odmaka, kao i činjenica da su svi modeli stabilni, u sljedećem koraku proveden je test Granger uzročnosti u multivarijantnom okruženju. Rezultati istoga prikazani su unutar Tablice 4.4.2.4. na način da su prikazani samo statistički značajni rezultati.

Kod prvog modela, s nominalnim cijenama nafte, uočena je statistički značajna Granger uzročnost u smjeru od DLOILN ka DLCPI. Ovo je ujedno i jedini pokazatelj cijena nafte za kojeg je test pokazao statistički značajnu Granger uzročnost u smjeru prema potrošačkim cijenama, odnosno inflaciji. Navedeni je rezultat, donekle očekivano, manje izražen kod

preostalih pokazatelja cijena nafte koji podrazumijevaju zasebne metode obračuna promjena cijena, te su kao takvi zasigurno primjenjiviji prilikom procjene utjecaja istih na pojedine realne ekonomske pokazatelje. Kod preostalih modela može se uočiti Granger uzročnost u smjeru od MORK+ prema kamatnoj stopi, kao i od NOPI4 prema novčanoj masi. Kada je riječ o kamatnoj stopi, može se istaknuti kako svi modeli detektiraju statistički značajnu Granger uzročnost u smjeru od deviznog tečaja (NEER) ka kamatnoj stopi (DIR), kao i od deviznog tečaja ka novčanoj masi (DLM1). Pored navedenog, može se uočiti i značajan utjecaj deviznog tečaja na inflaciju (DLCPI) kod svih modela osim onog s MORK+/MORK- pokazateljima cijene nafte. Konzistentnost ovih rezultata, kroz VAR modele s različitim pokazateljima cijena nafte, ukazuje na dobru definiranost modela kao i na robusnost generiranih rezultata analize.

Tablica 4.4.2.4.: Prikaz statistički značajnih rezultata Granger uzročnosti[179] procijenjenih VAR modela, multivarijantni okvir

VAR model s pokazateljem:	Detektirani smjer Granger uzročnosti
DLOILN	**DLOILN => DLCPI****
	DLOILN => DIR*
	DLNEER => DLCPI*
	DLNEER => DLM1*
	DLNEER => DIR*
	DLCPI => DIR*
	DIR => DLM1**
MORK+/MORK-	MORK+ => DIR*
	DLIPI => DIR**
	DLNEER => DLM1*
	DLNEER => DIR**
	DLCPI=> DLIPI*
	DIR => DLM1**
SOPI/SOPD	DLNEER => DLCPI**
	DLNEER => DLM1*
	DLNEER => DIR***
	DLCPI => DIR*
	DIR => DLM1**
NOPI4	DLNEER => DLCPI*
	DLNEER => DLM1*
	DIR => DLM1**
	NOPI4 => DLM1**
	DLCPI => DIR*
	DLNEER => DIR**

*, **, *** označavaju statistički značajan rezultat uz nivo signifikantnosti od, redoslijedno 10%, 5%, 1%.
Izvor: Izračun autorice

[179] *engl. VAR Granger causality/Block Exogeneity Wald Tests*

U sljedećem koraku, nad parametrima procijenjenih VAR sustava, provedeno je nekoliko dodatnih Wald testova s ciljem utvrđivanja jesu li u model uključene primjerene varijable, te utječu li jedna na drugu. Rezultati analize prikazani su u sklopu Tablice 4.4.2.5.

Kako bi se ispitalo utječu li cijene nafte na inflaciju neposredno, testirane su sljedeće hipoteze:

H_0: Koeficijenti pokazatelja cijena nafte jednaki su nuli u CPI jednadžbi promatranog VAR sustava jednadžbi.
H_1: Koeficijenti pokazatelja cijena nafte nisu jednaki nuli u CPI jednadžbi promatranog VAR sustava jednadžbi.

Provedeno testiranje potvrđuje prethodno iznesene rezultate Granger testa uzročnosti prema kojima je jedino kod DLOILN pokazatelja detektiran statistički značajan utjecaj cijena nafte na inflaciju. U ovom je slučaju rezultat statistički značajan na razini od 5%, što implicira odbacivanje nulte hipoteze testa za razliku od rezultata neposrednog utjecaja ostalih pokazatelja cijena nafte na inflaciju, a gdje nije moguće odbaciti nultu hipotezu (uz uobičajene razine pouzdanosti procjene).

Tablica 4.4.2.5.: Rezultati Wald testa – bivarijantni okvir

DLOIL	MORK+	MORK-	SOPI	SOPD	NOPI4
0,0372**[180]	0,2304	0,7628	0,1143	0,8570	0,5880

p vrijednosti hi kvadrat distribucije. Podebljane vrijednosti unutar ćelija označavaju statistički značajan rezultat na razini od 1%, 5% ili 10%, redoslijedno: ***,**,*.
Izvor: Izračun autorice

U sljedećem koraku, kako bi se procijenilo utječu li možda cijene nafte na inflaciju posredno putem preostalih odabranih varijabli u modelu; monetarnog agregata M1, kamatne stope, deviznog tečaja i indeksa industrijske proizvodnje; odnosno, testira se statistička značajnost procijenjenih parametara ispred varijable cijene nafte za cjelokupan VAR sustav (s izuzetkom jednadžbi pokazatelja cijena nafte i CPI za kojeg je već prethodno proveden Wald test).

U multivarijantnom okruženju, Wald testom su testirane sljedeće hipoteze:

[180] p vrijednosti hi-kvadrat distribucije za odabrane modele

H_0: Koeficijenti pokazatelja cijena nafte su jednaki nuli u svim jednadžbama procijenjenog VAR sustava osim u jednadžbi cijene nafte i CPI jednadžbi.
H_1: Koeficijenti pokazatelja cijena nafte nisu jednaki nuli u svim jednadžbama procijenjenog VAR sustava osim u jednadžbi cijene nafte i CPI jednadžbi.

Rezultati Wald testa, prikazani Tablicom 4.4.2.6. ukazuju na statistički značajan utjecaj cijena nafte na preostale varijable u VAR sustavu samo kod pokazatelja nominalne cijene nafte (DLOILN). Kombiniranjem navedenih rezultata s onima iz prethodne tablice može se konstatirati da je utjecaj cijena nafte na inflaciju posredan i neposredan, odnosno da se i posredno odvija putem preostalih varijabli uključenih u procjenu VAR sustava pri čemu navedeno vrijedi samo kod modela koji cijene nafte predstavlja pokazateljem nominalnih cijena. Kod preostalih modela nije detektiran statistički značajan utjecaj cijena nafte.

Tablica 4.4.2.6.: Rezultati Wald testa – multivarijantni okvir

DLOIL	MORK+	MORK-	SOPI	SOPD	NOPI4
0,0555*	0,5763	0,7059	0,8380	0,3808	0,1400

p vrijednosti hi kvadrat distribucije. Podebljane vrijednosti unutar ćelija označavaju statistički značajan rezultat na razini od 1%, 5% ili 10%, redoslijedno: ***,**,*.
Izvor: Izračun autorice

U daljnjoj analizi proveden je još jedan Wald test kako bi se ispitalo jesu li pozitivni i negativni koeficijenti pokazatelja cijena nafte jednaki u jednadžbama procijenjenih VAR sustava. Rezultati Wald testa indiciraju prihvaćanje odnosno odbacivanje postavljenih hipoteza:

H_0: Pozitivni i negativni koeficijenti pokazatelja cijena nafte su jednaki u CPI jednadžbi odnosno u ostalim jednadžbama promatranog VAR sustava.
H_1: Pozitivni i negativni koeficijenti pokazatelja cijena nafte nisu jednaki u CPI jednadžbi odnosno u ostalim jednadžbama promatranog VAR sustava.

Rezultati provedenog Wald testa (prikazani Tablicom 4.4.2.7.) upućuju na zaključak da nema statistički značajne razlike u utjecaju pokazatelja cijena nafte MORK+/MORK- i SOPI/SOPD na inflaciju, kao ni na preostale varijable obuhvaćene VAR modelima. Temeljem navedenog može se konstatirati da ne postoji asimetrija u utjecaju cijena nafte na odabrane monetarne varijable, kao ni na inflaciju.

Tablica 4.4.2.7.: Rezultati Wald testa jednakosti procijenjenih parametara pokazatelja pozitivnih i negativnih promjena cijena nafte

MORK+ = MORK-		SOPI = SOPD	
CPI jednadžba	VAR sustav jednadžbi	CPI jednadžba	VAR sustav jednadžbi
0,1646	0,4049	0,1210	0,3097

p vrijednosti hi kvadrat distribucije. Podebljane vrijednosti unutar ćelija označavaju statistički značajan rezultat na razini od 1%, 5% ili 10%, redoslijedno: ***,**,*.
Izvor: Izračun autorice

Neposredno prije provedbe inovacijske analize ispitana je i značajnost dummy varijable KRIZA. Rezultati Wald testa, sabrani unutar Tablice 4.4.2.8., upućuju na zaključak da je, neovisno o korištenom pokazatelju cijena nafte, utjecaj dummy varijable KRIZA na indeks industrijske proizvodnje negativan (što implicira predznak procijenjenih koeficijenata) i statistički značajan na razini od 1%.

Tablica 4.4.2.8.: Vrijednosti procijenjenih parametara ispred varijable KRIZA

Model s pokazateljem:	Utjecaj varijable KRIZA na:	Vrijednost procijenjenog parametra:
DLOILN	DLCPI	-0,001296*
	DLIPI	**-0,011614*** **
	DLNEER	-0,000550
	DLMI	-0,007285**
	DIR	-0,046686
MORK+/MORK-	DLCPI	-0,001543*
	DLIPI	**-0,014102*** **
	DLNEER	-0,001246
	DLMI	-0,007123*
	DIR	-0,025925
SOPI/SOPD	DLCPI	-0,000818
	DLIPI	**-0,012493*** **
	DLNEER	-0,000793
	DLMI	-0,006719*
	DIR	-0,059999
NOPI4	DLCPI	-0,001319*
	DLIPI	**-0,011422*** **
	DLNEER	-0,000612
	DLMI	-0,008119**
	DIR	-0,098182

*,**,*** indicira statistički značajan rezultat na razini od, redom; 10%, 5%, 1%.
Izvor: Izračun autorice

Na istovjetan utjecaj dummy varijable KRIZA na varijablu indeksa industrijske proizvodnje ukazala je i ekonometrijska analiza hipoteze H1 (što je i svojevrsna potvrda robusnosti rezultata). Pored navedenog, evidentan je i negativan utjecaj krize na novčanu masu (DLM1) pri čemu je isti statistički značajan uz razinu od 5% signifikantnosti kod modela s pokazateljima

DLOIL i NOPI4, odnosno u nešto manjoj mjeri (uz razinu od 10% signifikantnosti), kod modela s pokazateljima MORK+/MORK- i SOPI/SOPD.

Grafikonom 4.4.2.1. prikazane su funkcije impulsnog odziva varijable DLCPI pri čemu je šok u sustavu jednadžbi definiran kao promjena u visini jedne standardne devijacije varijable pokazatelja promjene cijena nafte; nominalne cijene nafte (DLNOIL), MORK+, MORK-, SOPI, SOPD i NOPI4. Sagledavanjem reakcije DLCPI na naftni šok nužno je, za početak, eliminirati one čiji utjecaj nije statistički značajan, a to su, tragom rezultata prethodne analize pa tako i IRFova; NOPI4, MORK+ i SOPD. Funkcije impulsnog odziva varijable DLCPI na šok u varijabli koja predstavlja cijene nafte pokazuju kako je reakcija DLCPI na nominalne cijene nafte (DLOIL) pozitivna u prva dva mjeseca, nakon čega prestaje biti statistički značajna. Ovaj je zaključak na tragu rezultata prethodno provedenih testova Granger uzročnosti, ali i Wald testova. Gotovo istovjetna je i reakcija DLCPI na šok u varijabli MORK-, ali i SOPI, što se pak nije moglo naslutiti temeljem prethodno provedene analize. Reakcija DLCPI na MORK+ i SOPI je veoma slična, no izgled funkcije implicira da utjecaj MORK+ na DLCPI nije statistički značajan. Upravo reakcija DLCPI na SOPI je najsnažnija i, za razliku od DLOILN i MORK-, statistički značajna 3 mjeseca po šoku u varijabli SOPI. Također, može se konstatirati da protokom, najdalje, konca prve godine (12 mjeseci) utjecaj cijena nafte na DLCPI u potpunosti iščezava (neovisno o korištenom pokazatelju cijena nafte).

Grafikon 4.4.2.1.: Impulsne funkcije odziva varijable DLCPI na šok od jedne standardne devijacije u varijablama koje predstavljaju pokazatelje cijena nafte u svim procijenjenim VAR modelima

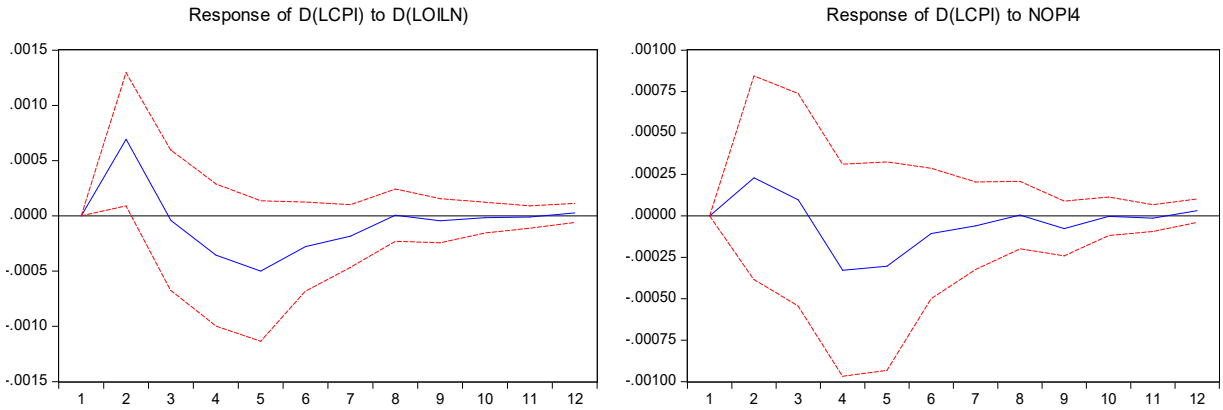

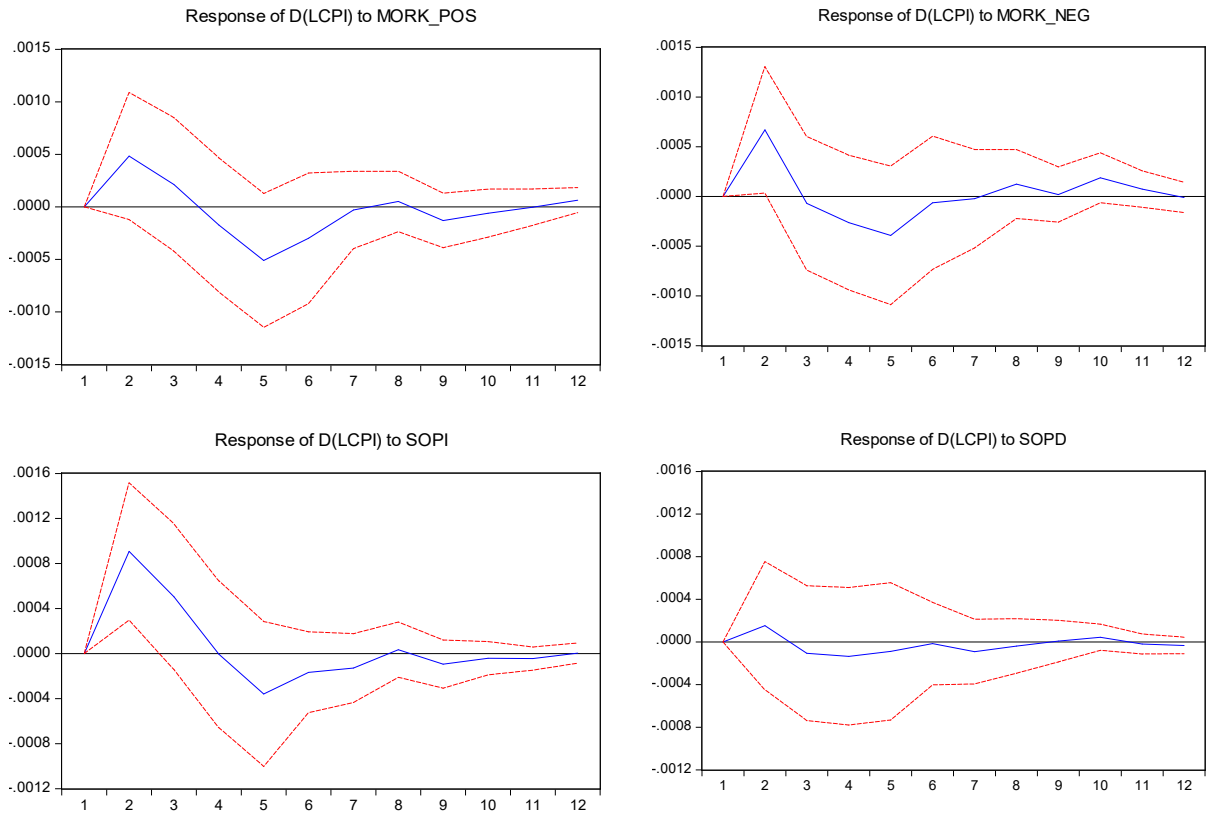

*Pune plave linije predstavljaju funkcije, isprekidane crvene linije odstupanje od dvije standardne devijacije (interval pouzdanosti procjene 95%), na ordinati su razine pojave izražene u mjernim jedinicama varijable, a na apscisi vrijeme izraženo u tromjesečjima.
Izvor: Izračun autorice

Podaci u Tablici 4.4.2.9. prikazuju rezultate dekompozicije varijance prognostičke greške za procijenjenu CPI jednadžbu VAR modela za period do 8 mjeseci (nakon šoka) i to na način da je ista razložena na doprinos pojedine varijable u sustavu ukupnoj varijanci prognostičke greške varijable DLCPI. Podaci o dekompoziciji varijance pokazuju da asimetrični pokazatelji cijena nafte MORK+ i MORK- pojašnjavaju manji dio varijance varijable DLCPI u odnosu na nominalne cijene nafte, do 5% zajedno. Kod SOPI/SOPD pokazatelja, SOPD pojašnjava gotovo neznatan dio varijance (manje od 1%) dok, istovremeno, na SOPI „otpada“ 5% varijance varijable DLCPI. Ono što je također važno istaknuti je da se udjeli unutar dekompozicije varijance relativno brzo stabiliziraju, od trećeg mjeseca nadalje njihove su promjene prilično skromne, što odgovara i prethodno provedenoj analizi funkcija impulsnog odziva.

Na tragu prethodno provedene analize Granger uzročnosti, i dekompozicije varijance varijable DLCPI impliciraju značajniji udio varijable DLNEER u pojašnjavanju varijance DLCPI (oko 4% koncem 8. mjeseca) što ne čudi kad se uzme u obzir način vođenja monetarne politike u RH i usmjerenost na devizni tečaj. Dekompozicija varijance varijable DLCPI pokazuje i da je

najveći dio varijacija analizirane varijable kroz vrijeme moguće objasniti samom varijablom DLCPI (od 100% početkom promatranog perioda do 85% koncem promatranog perioda), pri čemu se stabilizacija varijance može uočiti od 8. mjeseca na dalje (dekompozicije za periode 5, 6, i 7 su izuzete zbog skromnih promjena).

Tablica 4.4.2.9.: Dekompozicija varijance varijable DLCPI

Period	S.E.	D(LCPI)	D(LIPI)	D(LNEER)	D(LM1)	D(IR)	**D(LOILN)**
1	0.004491	100.0000	0.000000	0.000000	0.000000	0.000000	**0.000000**
2	0.004775	94.52076	0.448005	0.460105	1.438425	1.020134	**2.112569**
3	0.004862	91.72575	1.240634	1.853693	1.843875	1.291006	**2.045040**
4	0.005002	89.33837	1.646371	2.501753	2.804393	1.274368	**2.434744**
8	0.005085	86.83807	1.854666	3.061241	2.826381	1.669553	**3.750086**

Cholesky poredak varijabli: D(LCPI) D(LIPI) D(LNEER) D(LM1) D(IR) D(LOILN)

Period	S.E.	D(LCPI)	D(LIPI)	D(LNEER)	D(LM1)	D(IR)	**MORK_NEG**	**MORK_POS**
1	0.004569	100.0000	0.000000	0.000000	0.000000	0.000000	**0.000000**	**0.000000**
2	0.004914	93.53047	0.767385	0.558021	1.375671	0.944140	**1.856358**	**0.967955**
3	0.005011	90.25691	1.939923	2.020008	1.560451	1.307306	**1.804561**	**1.110845**
4	0.005116	88.45474	2.143143	3.066168	1.875900	1.285009	**1.995201**	**1.179840**
8	0.005247	84.43832	2.341481	4.381058	2.204849	1.700578	**2.527112**	**2.406598**

Cholesky poredak varijabli: D(LCPI) D(LIPI) D(LNEER) D(LM1) D(IR) MORK_NEG MORK_POS

Period	S.E.	D(LCPI)	D(LIPI)	D(LNEER)	D(LM1)	D(IR)	**SOPI**	**SOPD**
1	0.004466	100.0000	0.000000	0.000000	0.000000	0.000000	**0.000000**	**0.000000**
2	0.004800	93.14374	0.750190	0.107233	1.243443	1.081944	**3.572391**	**0.101057**
3	0.004925	88.76400	1.624223	2.173292	1.540720	1.308810	**4.446701**	**0.142252**
4	0.005021	87.08786	1.876676	3.340799	1.946101	1.259704	**4.279602**	**0.209254**
8	0.005108	84.59854	2.009304	4.354108	2.216286	1.748078	**4.803571**	**0.270114**

Cholesky poredak varijabli: D(LCPI) D(LIPI) D(LNEER) D(LM1) D(IR) SOPI SOPD

Izvor: Izračun autorice

Skromne varijacije inflacije očekivane su kad se uzme u obzir ranije analizirano kretanje inflacije u RH s obzirom na usmjerenost monetarnih vlasti na niske stope inflacije koja je u periodima niskih stopa realnog rasta BDP-a i visoke nezaposlenosti nerijetko bila i kritizirana. Na varijablu DLCPI, iako relativno skroman, najveći utjecaj ima upravo varijabla nominalnih cijena nafte (DLOILN) čije kretanje može pojasniti nešto manje od 4% varijance prognostičke greške DLCPI-a. Ipak, ako se izuzme udio varijance vlastite prognostičke pogreške, kod sva tri prikazana VAR modela cijene nafte su primarni izvor varijabilnosti varijable DLCPI (među preostalim odabranim varijablama modela).

Tablica 4.4.2.10.: Korigirani koeficijenti determinacije CPI jednadžbi procijenjenih VAR sustava

Model s pokazateljem:	$\overline{R}^2$
LOILN	**0,147500**
MORK+/MORK-	0,127912
SOPI/SOPD	0,146505
NOPI4	0,119072

Izvor: Izračun autorice

Kako bi se odgovorilo na pitanje koji je pokazatelj cijene nafte, a samim time i procijenjeni model, najprimjereniji, uspoređeni su korigirani koeficijenti determinacije CPI jednadžbi procijenjenih VAR modela (Tablica 4.4.2.10.), a potom i informacijski kriteriji istih (Tablica 4.4.2.11.). Rezultati prikazani u obje tablice upućuju na zaključak o korištenju nominalne cijene nafte kao najprimjerenijeg pokazatelja cijene nafte u analizi utjecaja cijena nafte na inflaciju.

Tablica 4.4.2.11.: Vrijednost Akaike (AIC) i Schwarz (SBC) informacijskih kriterija CPI jednadžbi procijenjenih VAR sustava

Model s pokazateljem:	AIC	SBC
LOILN	**-7,868806**	**-7,489396**
MORK+/MORK-	-7,801357	-7,274133
SOPI/SOPD	-7,859320	-7,438078
NOPI4	-7,827174	-7,457765

Izvor: Izračun autorice

U konačnici, temeljem provedene analize može se konstatirati da je najprimjereniji pokazatelj cijena nafte u ovom slučaju nominalna cijena nafte – DLOILN. Korištenjem preostalih pokazatelja cijena nafte nije dokazan asimetričan utjecaj cijena nafte na inflaciju, iako su funkcije impulsnog odziva pokazale da je, unutar prva dva mjeseca nakon inicijalnog šoka pokazatelja cijena nafte, utjecaj MORK- i SOPI na DLCPI statistički značajan i pozitivan, dok istovremeno utjecaj MORK+ i SOPD nije statistički značajan.

Zaključno, ekonometrijsko testiranje implicira **prihvaćanje hipoteze H2** odnosno zaključak o *statistički značajnom pozitivnom utjecaju cijena nafte na inflaciju*. Navedeni se rezultat treba razmotriti u kontekstu prve runde efekata promjena nominalnih cijena nafte, a to je direktni i najbrži utjecaj cijena nafte na cijene naftnih derivata, koji se gotovo trenutačno prelijeva na cijene naftnih derivata u zemlji (a samim time i na indeks potrošačkih cijena). Isti je, očekivano, manje izražen kod preostalih pokazatelja cijena nafte koji podrazumijevaju zasebne metode obračuna promjena cijena nafte, te su kao takvi zasigurno primjenjiviji prilikom procjene utjecaja istih na pojedine realne varijable.

4.4.3. Implikacije promjena cijena nafte na kretanje nezaposlenosti

S ciljem testiranja hipoteze *H3: Rast cijena nafte statistički značajno povećava nezaposlenost, dok pad cijena nafte nema statistički značajan utjecaj na nezaposlenost*, ekonometrijski su testirana 4 VAR modela sa odabranim varijablama Zt vektora (4.4.): *UNP* - stopom nezaposlenosti, *LWAGE* - prirodnim logaritmom realne plaće, *IRr* - realnom kamatnom stopom, *LOIL* - prirodnim logaritmom realne cijene nafte (odnosno pripadajućim pokazateljima cijene nafte; *MORK+, MORK-, SOPI, SOPD, NOPI*), te dummy varijablom - *KRIZA*. S obzirom da se administrativna stopa nezaposlenosti u Hrvatskoj počinje pratiti tek početkom 2000. godine, uzorak je smanjen te obuhvaća mjesečne podatke za period od siječnja 2000. do prosinca 2015., što daje 192 podataka po varijabli.

Iako je procjena prethodne hipoteze (H2) vršena nad mjesečnim podacima, uzorak je bio veći (1995:M01-2015:M12) zbog čega je opet bilo nužno utvrditi eventualno postojanje jediničnih korijena u korištenim (kraćim) vremenskim nizovima. Test veličine provedenih testova jediničnog korijena prikazane su unutar Tablice 4.4.3.1.

Tablica 4.4.3.1.: Rezultati testova jediničnog korijena za korištene vremenske nizove, mjesečni podaci (2000:M01-2015:M12)

	Model s konstantom i trendom			Model s konstantom			Model bez konstante	
	ADF	PP	KPSS	ADF	PP	KPSS	ADF	PP
LOIL	-1,06	-0,53	0,26***	-1,64	-1,61	1,11***	-0,21	-0,11
DLOIL	**-11,68*** **	**-11,66*** **	**0,08**	**-11,59*** **	**-11,59*** **	**0,31**	**-11,63*** **	**-11,62*** **
MORK+	**-14,27*** **	**-14,27*** **	**0,08**	**-13,76*** **	**-13,76*** **	**0,77*** **	**-2,85*** **	**-10,75*** **
MORK-	**-9,76*** **	**-9,73*** **	**0,07**	**-9,78*** **	**-9,75*** **	**0,08**	**-7,92*** **	**-8,16*** **
SOPI	**-15,88*** **	**-15,94*** **	**0,17** **	**-15,49*** **	**-15,48*** **	**0,62** **	**-2,39** **	**-11,71*** **
SOPD	**-11,83*** **	**-11,82*** **	**0,09**	**-11,85*** **	**-11,84*** **	**0,10**	**-9,35*** **	**-10,13*** **
NOPI4	**-11,59*** **	**-11,60*** **	**0,19** **	**-11,46*** **	**-11,50*** **	**0,43* **	**-3,36*** **	**-9,91*** **
UNP	-2,15	-1,02	0,36***	-2,07	-0,99	0,38**	-0,71	-0,11
DUNP	**-3,67** **	**-7,22*** **	**0,19** **	**-3,61*** **	**-7,17*** **	**0,27**	**-3,63*** **	**-7,19*** **
LWAGE	-1,53	-1,49	0,41***	-2,66*	-2,70*	1,102***	1,55	1,89
DLWAGE	**-16,89*** **	**-17,80*** **	**0,07**	**-16,58*** **	**-16,67*** **	**0,59** **	**-16,37*** **	**-16,42*** **
IRr	**-3,84** **	**-4,91*** **	**0,05**	**-3,90*** **	**-4,95*** **	**0,10**	**-3,85*** **	**-4,83*** **

Izvor: Izračun autorice

Rezultati provedenih testova jediničnog korijena; ADF, PP i KPSS testa (u tri, odnosno dva modaliteta) sugeriraju da je realna cijena nafte – LOIL stacionarna tek nakon diferenciranja, odnosno integrirana reda jedan - I(1), za razliku od ostalih pokazatelja cijena nafte (MORK+, MORK-, SOPI, SOPD, NOPI4) koji su stacionarni u razinama odnosno integrirani reda nula -

I(0). Što se tiče ostalih varijabli u modelu, stopa nezaposlenosti i realne plaće su stacionarne tek nakon diferenciranja, odnosno I(1), dok su realne kamatne stope stacionarne u razini, odnosno I(0). Temeljem navedenog, u daljnjem tijeku analize korištene su stacionarne (unutar Tablice 4.4.3.1 podebljanim slovima prikazane) varijable: prva diferencija stope nezaposlenosti – DUNP, prva diferencija prirodnog logaritma realne plaće - DLWAGE, realna kamatna stopa – IRr, prirodni logaritam realne cijene nafte – DLOIL, te preostali stacionarni pokazatelji cijena nafte: MORK+, MORK-, SOPI, SOPD i NOPI4, kao i dummy varijabla KRIZA. S obzirom na red integriranosti konačnog odabira varijabli, prvenstveno upućujući na kamatnu stopu koja je I(0), zbog različitog reda integriranosti varijabli u svim procijenjenim modelima, provjera postojanja kointegracije Johansenovim testom nije bila potrebna.

U daljnjem tijeku analize, korištenjem odabranih stacionarnih varijabli, provedeno je testiranje optimalnog broja vremenskih odmaka (u ovom slučaju mjeseci). Tablica 4.4.3.2. prikazuje konačno odabrane brojeve vremenskih odmaka za pojedine modela. Evidentno je da je broj vremenskih odmaka kod modela s MORK+/MORK- pokazateljima veći od ostalih (6 u odnosu na 3, odnosno 4 kod modela s preostalim pokazateljima), što je posljedica izraženog problema autokorelacije koji je anuliran tek procjenom modela sa 6 vremenskih odmaka.

Tablica 4.4.3.2.: Konačan broj vremenskih odmaka u procijenjenim VAR modelima

Pokazatelj cijena nafte	DLOIL	MORK+/MORK-	SOPI/SOPD	NOPI
Broj vremenskih odmaka procijenjenog VAR sustava (k)	4	6	3	3

Izvor: Izračun autorice

Nakon odabira optimalne duljine odmaka izvršena je i provjera pretpostavki modela, prvenstveno spomenuta provjera postojanja problema autokorelacije, a potom i problema heteroskedastičnosti kao i provjera oblika distribucije reziduala. Rezultati navedenih testova za sve procijenjene modele prikazani su u sklopu Priloga 2. Također, testirana je i stabilnost svih procijenjenih modela (vidjeti Prilog 2), pri čemu rezultati analize upućuju na zaključak da su svi procijenjeni VAR modeli stabilni.

U sljedećem je koraku, korištenjem stacionarnih vremenskih nizova, proveden Granger test uzročnosti u multivarijantnom okruženju. Rezultati istog prikazani su unutar Tablice 4.4.3.3. Rezultati Granger testa uzročnosti nisu detektirali Granger uzročnost u smjeru od pokazatelja cijena nafte prema stopi nezaposlenosti. Kod modela s realnom cijenom nafte Granger test

upućuje na uzročnost u smjeru od DLOIL prema realnoj kamatnoj stopi (i to na razini od 1% statističke značajnosti) te prema realnim plaćama, a kod MORK- prema realnoj kamatnoj stopi, ali uz nižu razinu značajnosti (što se može pojasniti i većim brojem vremenskih odmaka u navedenom modelu).

Tablica 4.4.3.3.: Prikaz statistički značajnih rezultata Granger uzročnosti procijenjenih VAR modela, multivarijantni okvir

VAR model s pokazateljem:	Detektirani smjer Granger uzročnosti
DLOIL	IRr => DLWAGE**
	DLOIL => DLWAGE*
	DUNP => IRr*
	DLOIL => IRr*
MORK+/MORK-	IRr => DLWAGE**
	MORK- => IRr*
SOPI/SOPD	**IRr => DLWAGE***
	DUNP => IRr**
NOPI4	**IRr => DLWAGE***
	DUNP => IRr**
	DLWAGE => IRr*

*, ** označavaju statistički značajan rezultat uz nivo signifikantnosti od, redoslijedno 10%, 5%.
Izvor: Izračun autorice

Kod prvog se modela može stoga zaključiti da realne cijene nafte Granger uzrokuju realne plaće (DLWAGE) direktno i indirektno (preko Granger uzročnosti u smjeru prema realnoj kamatnoj stopi). Uz razinu od 5% statističke značajnosti može se istaknuti Granger uzročnost u smjeru od stope nezaposlenosti (DUNP) prema realnoj kamatnoj stopi (IRr) (kod svih modela osim kod modela s MORK+/MORK- pokazateljima). Istovremeno, uz razinu od 1% statističke značajnosti, u svim je procijenjenim modelima detektirana Granger uzročnost u smjeru od realne kamatne stope (IRr) prema realnim plaćama (DLWAGE). Izuzev navedenih veza, odnosno sugeriranih Granger uzročnosti, test ne sugerira direktan, a u ovoj fazi empirijske provjere ni indirektan, utjecaj cijena nafte na nezaposlenost.

Slijedi procjena VAR modela, kako bi se temeljem istih, a neposredno prije primjene alata inovacijske analize, izvršilo testiranje statističke značajnosti procijenjenih parametara. Kako bi se ispitalo utječu li cijene nafte na stopu nezaposlenosti direktno, testirane su sljedeće hipoteze:

H_0: Koeficijenti pokazatelja cijena nafte jednaki su nuli u jednadžbi UNP promatranog VAR sustava jednadžbi.

H_1: Koeficijenti pokazatelja cijena nafte nisu jednaki nuli u jednadžbi UNP promatranog VAR sustava jednadžbi.

Rezultati su prikazani u sklopu Tablice 4.4.3.4. unutar koje su istaknute *p* vrijednosti hi kvadrat distribucije za provedeni test. Rezultati provedenih Wald testova nad procijenjenim parametrima VAR sustava impliciraju da se prihvaća hipoteza H_0 kod svih procijenjenih VAR sustava, odnosno da procijenjeni koeficijenti u UNP jednadžbama nisu statistički značajno različiti od nule. Tragom navedenog može se konstatirati da eventualni direktan utjecaj cijena nafte na stopu nezaposlenosti, neovisno o načinu iskazivanja promjena cijena nafte, nije statistički značajan. Navedeni rezultati potvrđuju i zaključke prethodno provedene analize Granger uzročnosti.

Tablica 4.4.3.4.: Rezultati Wald testa – bivarijantni okvir

DLOIL	MORK+	MORK-	SOPI	SOPD	NOPI4
0,4699**[181]	0,7289	0,8493	0,3037	0,6785	0,7992

p vrijednosti hi kvadrat distribucije. Podebljane vrijednosti unutar ćelija označavaju statistički značajan rezultat na razini od 1%, 5% ili 10%, redoslijedno: ***,**,*.
Izvor: Izračun autorice

Kako bi se procijenilo utječu li možda cijene nafte na stopu nezaposlenosti posredno putem preostalih odabranih varijabli u modelu (realnih plaća i/ili realne kamatne stope) testirana je statistička značajnost pokazatelja cijena nafte u kontekstu cjelokupnih VAR sustava. Konkretno, Wald testom su testirane sljedeće hipoteze:

H_0: Koeficijenti pokazatelja cijena nafte su jednaki nuli u svim jednadžbama procijenjenog VAR sustava osim u jednadžbi cijene nafte i UNP jednadžbi.
H_1: Koeficijenti pokazatelja cijena nafte nisu jednaki nuli u svim jednadžbama procijenjenog VAR sustava osim u jednadžbi cijene nafte i UNP jednadžbi.

Rezultati Wald testa, prikazani Tablicom 4.4.3.5., pokazuju statistički značajan utjecaj cijena nafte na preostale varijable u VAR sustavu (odbacivanje H_0) samo kod VAR modela u kojem su cijene nafte prikazane realnim cijenama. Navedeni se rezultat naslanja na prethodno detektiranu Granger uzročnost u smjeru od realnih cijena nafte prema realnim plaćama, odnosno realnoj kamatnoj stopi. Kod svih su ostalih VAR modela prihvaćene nulte hipoteze, odnosno Wald test upućuje na zaključak da, u preostalim jednadžbama procijenjenih VAR

[181] p vrijednosti hi-kvadrat distribucije za odabrane modele

sustava, procijenjeni koeficijenti pokazatelja cijena nafte nisu statistički značajno različiti od nule.

Tablica 4.4.3.5.: Rezultati Wald testa – multivarijantni okvir

DLOIL	MORK+	MORK-	SOPI	SOPD	NOPI4
0,0000****	0,5806	0,2383	0,1680	0,1898	0,3556

p vrijednosti hi kvadrat distribucije. Podebljane vrijednosti unutar ćelija označavaju statistički značajan rezultat na razini od 1%, 5% ili 10%, redoslijedno: ***,**,*.
Izvor: Izračun autorice

Nadalje je proveden još jedan Wald test kako bi se ispitalo jesu li pozitivni i negativni koeficijenti pokazatelja cijena nafte jednaki u jednadžbama procijenjenih VAR modela, odnosno, postoji li statistički značajna razlika između pokazatelja koji se odnose na pozitivne promjene cijena nafte (MORK+ i SOPI) i pokazatelja koji se odnose na negativne promjene cijena nafte (MORK- i SOPD). Cilj ove analize je ustanoviti postoji li statistički značajna razlika u visini procijenjenih koeficijenata ovisno o tome odnosi li se odabrani pokazatelj na povećanja ili smanjenja cijena nafte. Tablicom 4.4.3.6. su prikazani rezultati provedenog Wald testa koji indiciraju prihvaćanje odnosno odbacivanje hipoteza:

H_0: Pozitivni i negativni koeficijenti pokazatelja cijena nafte su jednaki u UNP jednadžbi odnosno u preostalim jednadžbama promatranog VAR sustava.
H_1: Pozitivni i negativni koeficijenti pokazatelja cijena nafte nisu jednaki u UNP jednadžbi odnosno u preostalim jednadžbama promatranog VAR sustava.

Tablica 4.4.3.6.: Rezultati Wald testa jednakosti procijenjenih parametara pokazatelja pozitivnih i negativnih promjena cijena nafte

MORK+ = MORK-		SOPI = SOPD	
UNP jednadžba	VAR sustav jednadžbi	UNP jednadžba	VAR sustav jednadžbi
0,8147	**0,0156****	0,3497	**0,0050*****

p vrijednosti hi kvadrat distribucije. Podebljane vrijednosti unutar ćelija označavaju statistički značajan rezultat na razini od 1%, 5% ili 10%, redoslijedno: ***,**,*.
Izvor: Izračun autorice

Temeljem rezultata Wald testa može se zaključiti da ne postoji statistički značajna razlika u visini procijenjenih koeficijenata pozitivnih i negativnih promjena cijena nafte u jednadžbi u kojoj je DUNP zavisna varijabla. Navedeni zaključak stoji neovisno o tome koriste li se MORK+/MORK- ili SOPI/SOPD pokazatelji. S druge strane, ako se sagledaju preostale jednadžbe procijenjenih VAR sustava, Wald test implicira statistički značajnu razliku u utjecaju

pozitivnih i negativnih pokazatelja cijena nafte na preostale varijable u sustavu, i to na razini od 5% kod MORK+/MORK- pokazatelja, odnosno na razini od 1% kod SOPI/SOPD. Važno je istaknuti da navedeni rezultati ne ukazuju na smjer, kao ni na intenzitet veze između cijena nafte i ostalih varijabli u procijenjenim VAR sustavima.

Detaljnijim sagledavanjem statističke značajnosti pojedinih procijenjenih koeficijenata, analiza je pokazala da se ovakav rezultat Wald testa javlja kao posljedica činjenice da VAR modeli s MORK+/MORK- i SOPI/SOPD pokazateljima (u prvom mjesecu nakon šoka) pokazuju statistički značajan negativan utjecaj rasta cijena nafte (predstavljenim MORK+ i SOPI pokazateljima) na realne plaće – DLWAGE (pri čemu pozitivni efekti pada cijena nafte na rast realnih plaća izostaju), kao i statistički značajan negativan utjecaj pada cijena nafte (predstavljenim MORK- i SOPD pokazateljima) na realnu kamatnu stopu.

U sljedećem koraku, prije same inovacijske analize, analizirana je i statistička značajnost dihotomne dummy varijable KRIZA. Rezultati provedene analize, sažeti u Tablici 4.4.3.7., ukazuju na činjenicu da kriza statistički značajno na razini od 1%, odnosno 5%, utječe na sve odabrane varijable (i u svim procijenjenim VAR modelima na isti način, što potvrđuje njihovu dobru definiranost) i to: statistički značajno negativno na realne plaće, odnosno statistički značajno pozitivno na stopu nezaposlenosti, kao i na realnu kamatnu stopu.

Tablica 4.4.3.7.: Statistička značajnost dummy varijable KRIZA

Model s pokazateljem:	Utjecaj varijable KRIZA na:	Vrijednost procijenjenog parametra:
DLOIL	**DUNP**	**0,089947*** **
	DLWAGE	**-0,005650*** **
	IRr	**0,806944** **
MORK+/MORK-	**DUNP**	**0,080113** **
	DLWAGE	**-0,007284*** **
	IRr	**1,108074** **
SOPI/SOPD	**DUNP**	**0,095859*** **
	DLWAGE	**-0,005983*** **
	IRr	**0,813430** **
NOPI4	**DUNP**	**0,087825*** **
	DLWAGE	**-0,005269*** **
	IRr	**0,777952** **

*,**,*** indicira statistički značajan rezultat na razini od, redom; 10%, 5%, 1%.
Izvor: Izračun autorice

Završni dio analize podrazumijeva korištenje alata inovacijske analize: funkcija impulsnog odaziva i dekompozicija varijance. Grafikonom 4.4.3.1. prikazane su funkcije impulsnog odziva varijabli u sustavu pri čemu je šok u sustavu jednadžbi definiran kao promjena pokazatelja cijena nafte (DLOIL, MORK+, MORK-, SOPI, SOPD i NOPI4) u visini jedne standardne devijacije.

Uzimajući u obzir prethodno navedene kriterije, funkcije impulsnog odziva varijable DUNP na šok u varijabli koja predstavlja cijene nafte pokazuju kako reakcija stope nezaposlenosti na promjene cijena nafte nije statistički značajna, ni u jednom od procijenjenih modela. Kod modela sa SOPI/SOPD pokazateljima cijene nafte, funkcija impulsnog odziva pokazuje pozitivan utjecaj varijable SOPI na stopu nezaposlenosti u 4 mjesecu nakon inicijalnog šoka. Ipak, donja granica procijenjenog intervala se smjestila blago ispod horizontalne linije grafikona, a ni prethodna analiza (Granger uzročnosti, kao ni Wald testovi procijenjenih koeficijenata) nije dala naslutiti statistički značajan utjecaj varijable SOPI na stopu nezaposlenosti, stoga je uputno i navedeni rezultat uzeti s rezervom.

Grafikon 4.4.3.1.: Impulsne funkcije odziva varijable DUNP na šok od jedne standardne devijacije u varijablama koje predstavljaju pokazatelje cijena nafte u svim procijenjenim VAR modelima

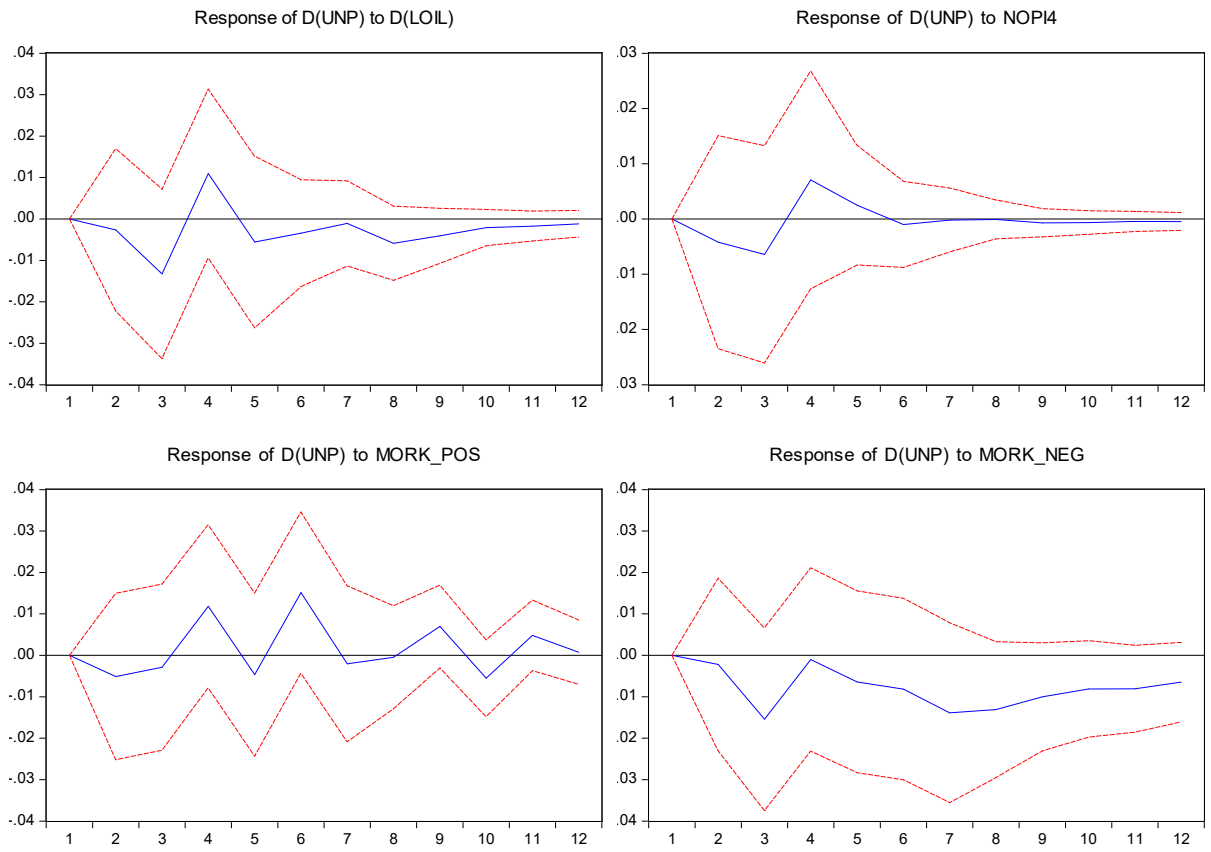

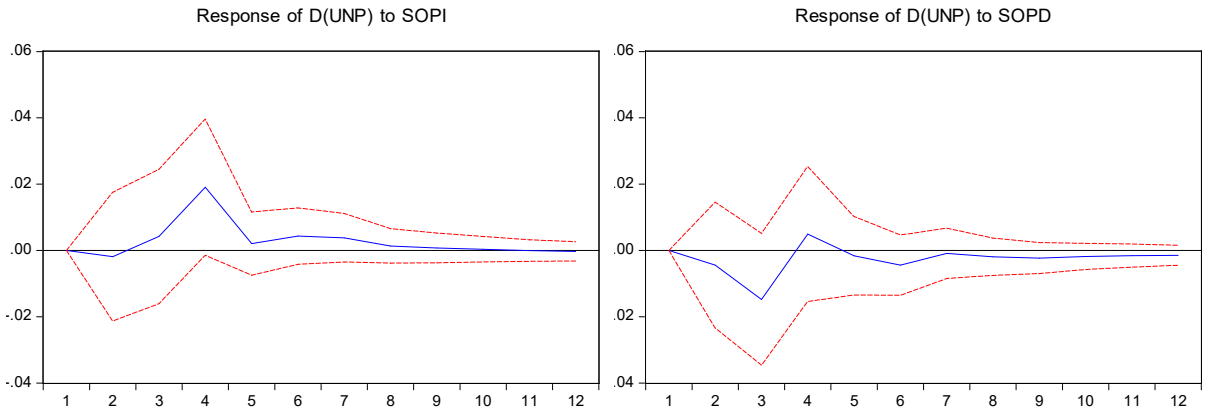

*Pune plave linije predstavljaju funkcije, isprekidane crvene linije odstupanje od dvije standardne devijacije (interval pouzdanosti procjene 95%), na ordinati su razine pojave izražene u mjernim jedinicama varijable, a na apscisi vrijeme izraženo u tromjesečjima.
Izvor: Izračun autorice

S obzirom na prikazane rezultate funkcija impulsnog odziva, dekompozicije varijanci prognostičke greške (koje su, očekivano, prikazivale izrazito skroman udio varijance varijable DUNP koji bi se mogao pripisati kretanjima cijena nafte) nisu ni prikazane s obzirom na prethodno doneseni zaključak o nepostojanju statistički značajnog utjecaja cijena nafte na kretanje stope nezaposlenosti, neovisno o korištenom pokazatelju.

Kako bi se identificirao najprimjereniji pokazatelj cijena nafte, uspoređeni su korigirani koeficijenti determinacije UNP jednadžbi procijenjenih VAR modela (Tablica 4.4.3.8.), a potom i Akaike i Schwarz informacijski kriteriji istih (Tablica 4.4.3.9.) s ciljem definiranja jednadžbe s višim koeficijentom determinacije, odnosno nižim vrijednostima informacijskih kriterija.

Tablica 4.4.3.8.: Korigirani koeficijenti determinacije UNP jednadžbi procijenjenih VAR sustava

Model s pokazateljem:	$\bar{R}^2$
LOIL	0,419446
MORK+/MORK-	0,419551
SOPI/SOPD	**0,430411**
NOPI4	0,425257

Izvor: Izračun autorice

Najviši korigirani koeficijent determinacije detektiran je kod jednadžbe sa SOPI/SOPD pokazateljima, pri čemu i Akike i Schwarz informacijski kriteriji upućuju na zaključak da je navedeni pokazatelj cijena nafte najprimjereniji.

Na koncu, može se zaključiti kako je provedena analiza pokazala da iako je unutar definiranih modela identificiran niz statistički značajnih veza, stopa nezaposlenosti ne reagira statistički značajno na promjene cijena nafte, neovisno o korištenom pokazatelju cijena nafte.

Tablica 4.4.3.9.: Vrijednost Akaike (AIC) i Schwarz (SBC) informacijskih kriterija UNP jednadžbi procijenjenih VAR sustava

Model s pokazateljem:	AIC	SBC
LOIL	-1,154098	-0,843082
MORK+/MORK-	-1,088383	-0,531348
SOPI/SOPD	**-1,186258**	**-0,943601**
NOPI4	-1,171774	-0,880762

Izvor: Izračun autorice

Shodno tome, empirijski rezultati upućuju na **odbacivanje hipoteze H3**: *rast cijena nafte statistički značajno povećava nezaposlenost, dok pad cijena nafte nema statistički značajan utjecaj na nezaposlenost*. Drugim riječima, nije dokumentirana statistički značajna neposredna reakcija stope nezaposlenosti na cijene nafte pa tako ni postojanje asimetrije u odnosu između stope nezaposlenosti i cijena nafte.

4.4.4. Promjene osobne potrošnje inicirane promjenama cijena nafte

S ciljem testiranja hipoteze *H4: Promjene cijena nafte statistički značajno negativno utječu na kretanje osobne potrošnje*, općim oblikom VAR modela (4.4.) obuhvaćene su tromjesečne varijable Zt vektora; *LCONS* - prirodni logaritam realne osobne potrošnje (u stalnim cijenama 2010.) , *LDI* - prirodni logaritam realnog raspoloživog dohotka[182], *UNP* – stopa nezaposlenosti, *LOIL* - prirodni logaritam realne cijene nafte (odnosno pripadajući pokazatelj cijena nafte; *MORK+, MORK-, SOPI, SOPD, NOPI4*), te dummy varijabla - *KRIZA*. Uvažavajući dostupnost odabranih vremenskih nizova, konačan se uzorak odnosi na vremenski period od prvog tromjesečja 2000. do posljednjeg tromjesečja 2015. godine.

U prvom je koraku analize provedeno ispitivanje stohastičkih svojstava korištenih vremenskih nizova te su Tablicom 4.4.4.1. prikazani rezultati testova jediničnog korijena za korištene vremenske nizove. Temeljem provedene analize može se konstatirati, na tragu dosadašnjeg tijeka istraživanja, da je realna cijena nafte nestacionarna u razini, odnosno da je stacionarnost

[182] Po uzoru na *Tica i Rosan (2014*) koji su istraživali čimbenike kretanja funkcije realne potrošnje kućanstva u RH, raspoloživi dohodak je aproksimiran realnom masom plaća; množenjem prosječne realne plaće i ukupnog broja zaposlenih.

postignuta prvom diferencijom. Stoga se može zaključiti da je ista I(1). Preostali pokazatelji cijena nafte; MORK+, MORK, SOPI, SOPD i NOPI4, stacionarni su u razinama ili I(0). Preostale tri varijable kojima su predstavljene osobna potrošnja (LCONS), raspoloživi dohodak (LDI) i nezaposlenost (UNP), također su stacionarne nakon diferenciranja. Shodno navedenom, u daljnjem su tijeku provjere postavljene hipoteze, a sukladno naznakama u Tablici 4.4.4.1., korištene varijable u stacionarnom obliku: prva diferencija prirodnog logaritma realne cijene nafte - DLOIL, preostali pokazatelji cijena nafte u razini; MORK+, MORK-, SOPI, SOPD, NOPI4, prva diferencija logaritma osobne potrošnje - DLCONS, prva diferencija logaritma realnog raspoloživog dohotka – DLDI, prva diferencija stope nezaposlenosti – DUNP, te dihotomna dummy varijabla KRIZA.

Tablica 4.4.4.1.: Rezultati testova jediničnog korijena za korištene vremenske nizove, tromjesečni podaci (2000:Q1-2015:Q4)

	Model s konstantom i trendom			Model s konstantom			Model bez konstante	
	ADF	PP	KPSS	ADF	PP	KPSS	ADF	PP
LOIL	-0,64	-0,78	0,19***	-1,49	-1,59	0,69**	-0,03	-0,04
DLOIL	**-6,53*** **	**-6,43*** **	**0,11**	**-6,38*** **	**-6,24*** **	**0,26**	**-6,43*** **	**-6,30*** **
MORK+	**-7,46*** **	**-7,46*** **	**0,15** **	**-7,29*** **	**-7,28*** **	**0,39***	**-2,68*** **	**-4,82*** **
MORK-	**-6,09*** **	**-6,06*** **	**0,07**	**-6,04*** **	**-6,07*** **	**0,16**	**-5,02*** **	**-4,97*** **
SOPI	**-7,87*** **	**-7,87*** **	**0,08**	**-7,93*** **	**-7,93*** **	**0,09**	**-7,84*** **	**-7,84*** **
SOPD	**-7,49*** **	**-7,48*** **	**0,06**	**-7,47*** **	**-7,47*** **	**0,12**	**-6,40*** **	**-6,47*** **
NOPI4	**-6,64*** **	**-6,64*** **	**0,16** **	**-6,54*** **	**-6,53*** **	**0,29**	**-5,39*** **	**-5,46*** **
LCONS	-2,09	-1,58	0,25***	-2,60*	-2,61*	0,45*	0,99	1,24
DLCONS	**-3,77** **	**-4,35*** **	**0,10**	**-3,02*** **	**-3,50*** **	**0,55***	**-1,93** **	**-3,22*** **
LDI	-2,08	-1,21	0,24***	-2,31	-2,14	0,60**	0,78	1,74
DLDI	**-5,65*** **	**-5,77*** **	**0,09**	**-5,09*** **	**-5,29*** **	**0,43***	**-4,81*** **	**-4,99*** **
UNP	-2,51	-1,19	0,22***	-2,43	-1,16	0,23	-0,81	-0,14
DUNP	**-3,07** **	**-2,97** **	**0,12***	**-2,97** **	**-2,87** **	**0,21**	**-3,01*** **	**-2,92*** **

*,**,*** indicira statistički značajan rezultat na razini od, redom; 10%, 5%, 1%.
Izvor: Izračun autorice

Varijable kojima se konstruira VAR model s realnom cijenom nafte (DLOIL, DLCONS, DLDI i DUNP) imaju isti red integracije (I(1)), stoga je Johansen testom ispitano eventualno postojanje kointegracije među njima. Rezultati provedenog testa prikazani su Tablicom 4.4.4.2. Rezultati testa traga matrice svojstvenih vrijednosti, kao i testa najveće svojstvene vrijednosti, upućuju na prihvaćanje nulte, odnosno odbacivanje alternativne hipoteze iz čega slijedi zaključak da među odabranim varijablama ne postoji kointegracija. Tragom navedenih rezultata, u daljnjem tijeku provjere postavljene hipoteze opravdano je korištenje VAR modela.

Tablica 4.4.4.2.: Rezultati Johansenovog testa kointegracije za VAR sustav jednadžbi (varijable: LCONS, LDI, UNP, LOIL)

Test traga matrice

H_0: r =	Svojstvena vrijednost	Test veličina	Kritična vrijednost 0,05	Vjerojatnost**
0	0.304187	43.68449	47.85613	0.1167
1	0.144128	21.19868	29.79707	0.3454
2	0.121021	11.54933	15.49471	0.1799
3	0.055675	3.551693	3.841466	0.0595

* označava odbacivanje nulte hipoteze pri razini od 5% značajnosti
***p* vrijednosti prema MacKinnon-Haug-Michelis (1999)

Test najveće svojstvene vrijednosti

H_0: r =	Svojstvena vrijednost	Test veličina	Kritična vrijednost 0,05	Vjerojatnost**
0	0.304187	22.48581	27.58434	0.1965
1	0.144128	9.649352	21.13162	0.7768
2	0.121021	7.997639	14.26460	0.3790
3	0.055675	3.551693	3.841466	0.0595

* označava odbacivanje nulte hipoteze pri razini od 5% značajnosti
***p* vrijednosti prema MacKinnon-Haug-Michelis (1999)

Izvor: Izračun autorice

Slijedi provjera postavljene hipoteze H4 na način da se procjenjuju 4 VAR sustava jednadžbi ovisno o tome koji je pokazatelj cijene nafte korišten. Svi sustavi obuhvaćaju varijable realne osobne potrošnje, realnog raspoloživog dohotka i stope nezaposlenosti, kao i dummy varijablu KRIZA, dok se pokazatelji cijena nafte permutiraju kroz 4 VAR sustava i to; 1) realna cijena nafte (točnije prva diferencija prirodnog logaritma iste), 2) MORK+ i MORK-, 3) SOPI i SOPD i 4) NOPI4.

Nakon što su ispitana stohastička svojstva vremenskih nizova, u sljedećem koraku procijenjen je optimalan broj vremenskih odmaka. Procedura određivanja optimalnog broja vremenskih odmaka izvršena je za sva 4 VAR sustava jednadžbi, ovisno o korištenim pokazateljima cijena nafte. Tablica 4.4.4.3. prikazuje konačno odabran broj vremenskih odmaka u procijenjenom modelu uvažavajući prethodno postavljene kriterije.

Tablica 4.4.4.3.: Konačan broj vremenskih odmaka u procijenjenim VAR modelima

Pokazatelj cijena nafte	DLOIL	MORK+/MORK-	SOPI/SOPD	NOPI4
Broj vremenskih odmaka procijenjenog VAR sustava (k)	1	1	1	3

Izvor: Izračun autorice

Među definiranim VAR sustavima jedino je onaj s NOPI4 pokazateljem cijene nafte procijenjen s 3 vremenska odmaka jer je procjena VAR sustava s manjim brojem vremenskih odmaka, kako su sugerirali informacijski kriteriji, rezultirala lošijim dijagnostičkim karakteristikama modela. Kod ostalih je VAR sustava odabran broj vremenskih odmaka k=1, implicirajući da se većina međuodnosa među odabranim varijablama odvija unutar prvog tromjesečja nakon šoka (u jednoj od varijabli procijenjenog sustava). Imperativ prilikom procijene modela ja da isti bude stabilan, što potvrđuju analize stabilnosti procijenjenih VAR sustava, a svakako je važno i da procijenjeni modeli produciraju što bolje dijagnostičke karakteristike. Rezultati analize stabilnosti kao i dijagnostika procijenjenih modela nalaze se u sklopu Priloga 2 ove disertacije.

Nakon što je prethodno ustanovljeno da je VAR model stabilan, te da među odabranim varijablama nije detektirano postojanje kointegracije, u sljedećem koraku proveden je test Granger uzročnosti u multivarijantnom okruženju (vidjeti Tablicu 4.4.4.4.).

Tablica 4.4.4.4.: Prikaz statistički značajnih rezultata Granger uzročnosti procijenjenih VAR modela, multivarijantni okvir

VAR model s pokazateljem:	Detektirani smjer Granger uzročnosti
DLOIL	DUNP => DLCONS* **DLCONS=> DLDI****
MORK+/MORK-	DLCONS=> DLDI* DUNP => DLDI* MORK- => DLDI*
SOPI/SOPD	DUNP => DLCONS* DUNP => DLDI* SOPI => DLDI*
NOPI4	NOPI4 => DLCONS* **DLCONS=> DLDI***** DUNP => DLDI*

*, **, *** označavaju statistički značajan rezultat uz nivo signifikantnosti od, redoslijedno 10%, 5%, 1%.
Izvor: Izračun autorice

Jedino je u VAR sustavu s NOPI4 pokazateljem cijena nafte detektirana Granger uzročnost u smjeru od cijena nafte ka osobnoj potrošnji (koja bi mogla sugerirati značajan međusobni utjecaj u navedenom smjeru) i to uz razinu signifikantnosti od, relativno skromnih, 10%. Granger uzročnost u smjeru od pokazatelja cijena nafte prema ostalim varijablama u modelu uočava se i kod modela s MORK+/MORK- pokazateljima cijena nafte gdje se, na razini od 10% signifikantnosti, može uočiti Granger uzročnost u smjeru od MORK- prema raspoloživom dohotku, kao i kod modela sa SOPI/SOPD pokazateljima gdje je evidentirana Granger uzročnost u smjeru od SOPI prema raspoloživom dohotku. Kod preostalih uočenih veza može se istaknuti, na razini 5%, odnosno 1% signifikantnosti, kod modela s DLOIL, odnosno NOPI4,

pokazateljem, Granger uzročnost u smjeru od osobne potrošnje ka raspoloživom dohotku. Granger uzročnost prema raspoloživom dohotku detektirana je i iz smjera nezaposlenosti.

Slijede testiranja nad parametrima procijenjenih VAR sustava s ciljem detekcije jesu li u model uključene primjerene varijable te utječu li jedna na drugu. Kako bi se ispitalo utječu li, različitim pokazateljima predstavljene, cijene nafte na realnu potrošnju (DLCONS) neposredno, testirane su sljedeće hipoteze:

H_0: Koeficijenti pokazatelja cijena nafte jednaki su nuli u jednadžbi CONS promatranog VAR sustava jednadžbi.
H_1: Koeficijenti pokazatelja cijena nafte nisu jednaki nuli u jednadžbi CONS promatranog VAR sustava jednadžbi.

Rezultati analize prikazani su Tablicom 4.4.4.5. Rezultati provedenih Wald testova nad procijenjenim parametrima VAR sustava impliciraju odbacivanje H_0 u CONS jednadžbi procijenjenih VAR sustava kod svih pokazatelja cijena nafte osim NOPI4 gdje su koeficijenti pokazatelja cijena nafte u jednadžbi CONS statistički značajno različiti od nule, uz razinu signifikantnosti od 10%. Ovaj se rezultat može dovesti u vezu i s prethodno istaknutom Granger uzročnosti u smjeru od NOPI4 prema DLCONS, kao i, potencijalno, činjenicom da je ovaj VAR sustav procijenjen s većim brojem odmaka, a čime cijene nafte imaju više prostora (točnije vremena) za djelovanje na potrošnju.

Tablica 4.4.4.5.: Rezultati Wald testa – bivarijantni okvir

DLOIL	MORK+	MORK-	SOPI	SOPD	NOPI4
0,4984[183]	0.3582	0,2493	0,9454	0.1022	**0,0689***

p vrijednosti hi kvadrat distribucije. Podebljane vrijednosti unutar ćelija označavaju statistički značajan rezultat na razini od 1%, 5% ili 10%, redoslijedno: ***,**,*.
Izvor: Izračun autorice

Uvažavajući mogućnost postojanja i funkcioniranja alternativnih mehanizama prijenosa utjecaja cijena nafte na osobnu potrošnju (putem raspoloživog dohotka i stope nezaposlenosti) u sljedećem koraku Wald testom su testirane sljedeće hipoteze:

[183] p vrijednosti hi-kvadrat distribucije za odabrane modele

H_0: Koeficijenti pokazatelja cijena nafte su jednaki nuli u svim jednadžbama procijenjenog VAR sustava osim u jednadžbi cijene nafte i CONS jednadžbi.
H_1: Koeficijenti pokazatelja cijena nafte nisu jednaki nuli u svim jednadžbama procijenjenog VAR sustava osim u jednadžbi cijene nafte i CONS jednadžbi.

Rezultati Wald testa, prikazani Tablicom 4.4.4.6., ovoga puta pokazuju da nije detektiran statistički značajan utjecaj cijena nafte na preostale varijable VAR sustava, odnosno da se utjecaj cijena nafte na osobnu potrošnju, ako i postoji, ne odvija posredno putem raspoloživog dohotka i stope nezaposlenosti.

Tablica 4.4.4.6.: Rezultati Wald testa – multivarijantni okvir

DLOIL	MORK+	MORK-	SOPI	SOPD	NOPI4
0,4750	0,6627	0,1858	0,2085	0,4279	0,8890

p vrijednosti hi kvadrat distribucije. Podebljane vrijednosti unutar ćelija označavaju statistički značajan rezultat na razini od 1%, 5% ili 10%, redoslijedno: ***,**,*.
Izvor: Izračun autorice

U nastavku je ispitano jesu li pozitivni i negativni koeficijenti pokazatelja cijena nafte u procijenjenim jednadžbama jednaki, odnosno postoji li statistički značajna razlika u visini procijenjenih koeficijenata ovisno o tome odnosi li se odabrani pokazatelj na povećanja ili smanjenja cijena nafte. Rezultati Wald testa indiciraju prihvaćanje, odnosno odbacivanje postavljenih hipoteza:

H_0: Pozitivni i negativni koeficijenti pokazatelja cijena nafte su jednaki u jednadžbi CONS odnosno u svim jednadžbama promatranog VAR sustava.
H_1: Pozitivni i negativni koeficijenti pokazatelja cijena nafte nisu jednaki u jednadžbi CONS odnosno u svim jednadžbama promatranog VAR sustava.

Temeljem rezultata provedene analize, predočenih Tablicom 4.4.4.7., moguće je konstatirati da ne postoji statistički značajna razlika u visini procijenjenih parametara ovisno o tome odnose li se isti na povećanje ili smanjenje cijena nafte. Marginalno značajan rezultat, na razini od 10,5% signifikantnosti, upućuje na razliku u visinama procijenjenih SOPI i SOPD koeficijenata u jednadžbi koja prikazuje kretanje osobne potrošnje u ovisnosti o raspoloživom dohotku, stopi nezaposlenosti i SOPI/SOPD pokazateljima cijena nafte.

Tablica 4.4.4.7.: Rezultati Wald testa jednakosti procijenjenih parametara pokazatelja pozitivnih i negativnih promjena cijena nafte

MORK+ = MORK-		SOPI = SOPD	
CONS jednadžba	VAR sustav jednadžbi	CONS jednadžba	VAR sustav jednadžbi
0,2259	0,4794	0,1028	0,3538

p vrijednosti hi kvadrat distribucije. Podebljane vrijednosti unutar ćelija označavaju statistički značajan rezultat na razini od 1%, 5% ili 10%, redoslijedno: ***,**,*.
Izvor: Izračun autorice

Važno je, prije same inovacijske analize, prikazati i značajnost dummy varijable KRIZA. Rezultati provedene analize, prikazani Tablicom 4.4.4.8., ukazuju na činjenicu da, uz signifikantnost od 1%, prema svim procijenjenim VAR modelima, kriza statistički značajno negativno utječe na osobnu potrošnju. Pored navedenog, kod modela sa MORK+/MORK- i SOPI/SOPD pokazateljima cijena nafte, utjecaj krize na raspoloživi dohodak je negativan i statistički značajan uz razinu signifikantnosti od 10%. Kod preostala dva modela (s DLOIL i NOPI4) procijenjeni su pokazatelji također negativni, ali nisu statistički značajni.

Tablica 4.4.4.8.: Statistička značajnost dummy varijable KRIZA

Model s pokazateljem:	Utjecaj varijable KRIZA na:	Vrijednost procijenjenog parametra:
DLOIL	**DLCONS**	**-0,013099*** **
	DLDI	-0,006638
	DUNP	0,171721
MORK+/MORK-	**DLCONS**	**-0,014056*** **
	DLDI	**-0,008169* **
	DUNP	0,184051
SOPI/SOPD	**DLCONS**	**-0,013078*** **
	DLDI	**-0,008305* **
	DUNP	0,183617
NOPI4	**DLCONS**	**-0,010148** **
	DLDI	-0,002017
	DUNP	0,112676

*,**,*** indicira statistički značajan rezultat na razini od, redom; 10%, 5%, 1%.
Izvor: Izračun autorice

Funkcije impulsnog odziva (na Grafikonu 4.4.4.1.) varijable DLCONS na šok u varijabli koja predstavlja cijene nafte pokazuju kako reakcija DLCONS na promjenu cijena nafte, predstavljenu pokazateljima DLOIL, MORK+, MORK-, SOPI, i SOPD, nije statistički značajna. Ovaj zaključak se može potkrijepiti činjenicom da kod navedenih funkcija granice ± 2 standardne devijacije (što znači da bi se stvarna reakcija DLCONS trebala nalaziti unutar navedenog intervala uz 95% pouzdanosti) sijeku horizontalnu liniju prikazanih grafikona. Na tragu prethodno iznesenih rezultata ekonometrijske provjere hipoteze H4, o detektiranom

utjecaju NOPI4 pokazatelja na DLCONS, impulsna funkcija odziva pokazuje negativan utjecaj NOPI4 na DLCONS od konca drugog tromjesečja nadalje (do konca sedmog) pri čemu je utjecaj ipak granično statistički značajan (statistički značajan na razini signifikantnosti od 10%) jer je gornja granica intervala pouzdanosti od 95% ipak „naslonjena“ na horizontalnu liniju. Zanimljivo je usporediti i vrijeme potrebno za „smirivanje“ funkcije DLCONS nakon inicijalnog šoka koje je znatno kraće kod ostalih pokazatelja cijene nafte u odnosu na NOPI4. Ovo se može dovesti u direktnu vezu s odabranim brojem vremenskih odmaka procijenjenih VAR sustava koji je kod VAR sustava s NOPI4 pokazateljem $k = 3$, a kod svih ostalih sustava $k = 1$. Zanimljivo je uočiti i smjer reakcije funkcije DLCONS na pozitivne i negativne promjene cijena nafte (MORK+ i MORK- i SOPI i SOPD), koje slijede teorijski očekivani smjer kretanja, ali kako je ranije istaknuto, nisu statistički značajne.

Grafikon 4.4.4.1.: Impulsne funkcije odziva varijable DLCONS na šok od jedne standardne devijacije u varijablama koje predstavljaju pokazatelje cijena nafte u svim procijenjenim VAR modelima

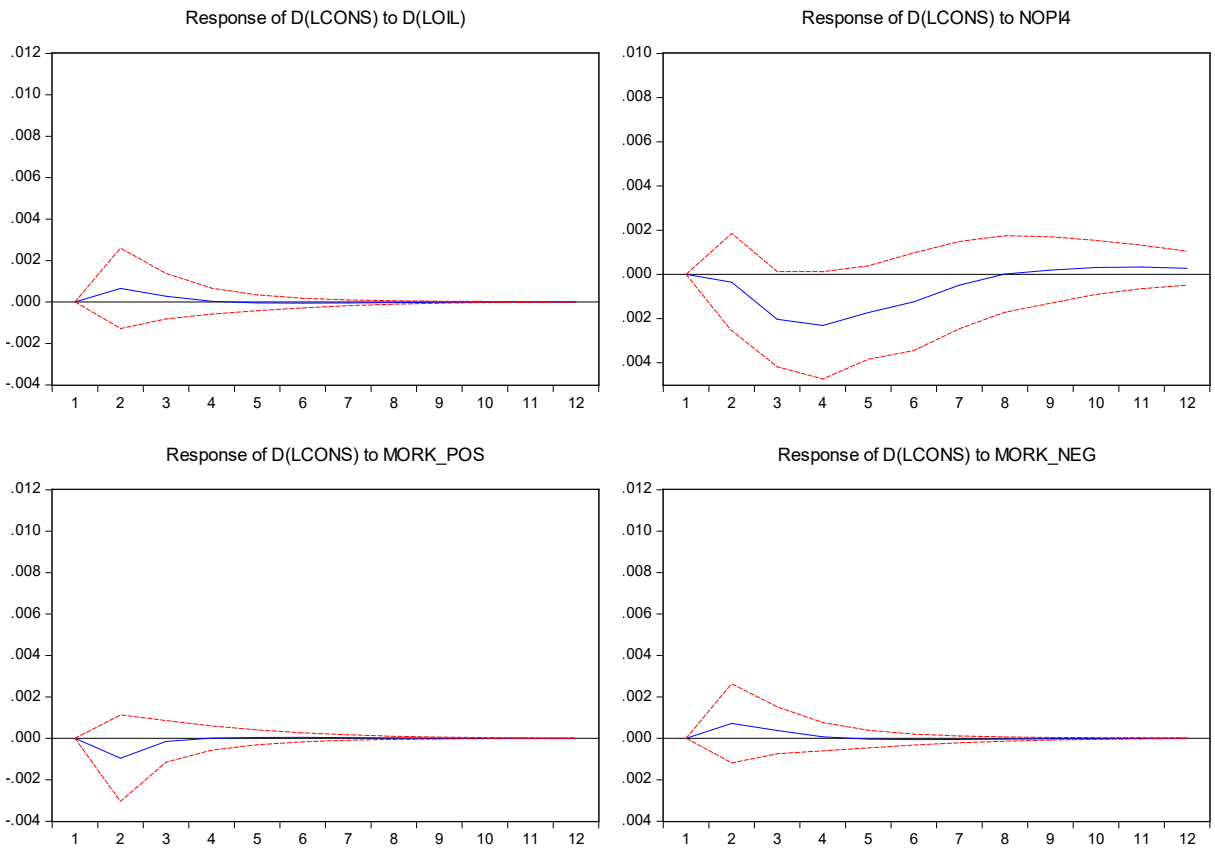

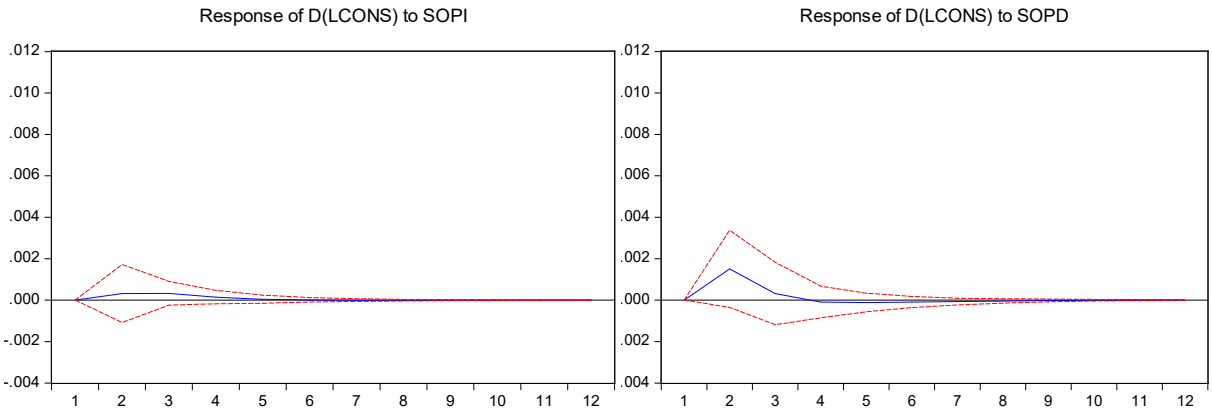

*Pune plave linije predstavljaju funkcije, isprekidane crvene linije odstupanje od dvije standardne devijacije (interval pouzdanosti procjene 95%), na ordinati su razine pojave izražene u mjernim jedinicama varijable, a na apscisi vrijeme izraženo u tromjesečjima.
Izvor: Izračun autorice

Konačno, Tablicom 4.4.4.9. prikazani su rezultati dekompozicije varijance prognostičke greške za procijenjenu DLCONS jednadžbu VAR modela s NOPI4 pokazateljem cijene nafte za period od tri godine (12 tromjesečja).

Tablica 4.4.4.9.: Dekompozicije varijance varijable DLCONS

Period	S.E.	**D(LCONS)**	D(LDI)	D(UNP)	**NOPI4**
1	0.007515	**100.0000**	0.000000	0.000000	**0.000000**
2	0.007721	**98.73945**	0.554234	0.499995	**0.206318**
3	0.008753	**87.12696**	1.378199	5.957715	**5.537128**
4	0.009282	**81.61094**	1.443559	5.828265	**11.11724**
5	0.009511	**77.90975**	1.395685	6.806834	**13.88773**
6	0.009630	**76.08588**	1.364467	7.339415	**15.21024**
7	0.009656	**75.73312**	1.397181	7.484832	**15.38487**
8	0.009674	**75.74510**	1.393151	7.533767	**15.32798**
9	0.009687	**75.75191**	1.389272	7.532845	**15.32597**
10	0.009700	**75.70799**	1.385657	7.516957	**15.38940**
11	0.009711	**75.64315**	1.382888	7.500734	**15.47322**
12	0.009717	**75.59091**	1.381366	7.492246	**15.53548**
Cholesky poredak varijabli: D(LCONS) D(LDI) D(UNP) NOPI4					

Izvor: Izračun autorice

Dekompozicije varijance DLCONS jednadžbi ostalih procijenjenih VAR sustava izuzete su zbog prethodno iznesenih zaključaka ekonometrijske analize koji nisu upućivali na postojanje statistički značajnog utjecaja istih na osobnu potrošnju . Kako je i uobičajeno, rezultati dekompozicije varijance pokazuju kako protekom definiranog vremenskog perioda varijabla DLCONS objašnjava veći dio varijance vlastite prognostičke pogreške, kao i da se taj udio s protekom vremena smanjuje i stabilizira na nekih 75% od sedmog tromjesečja nadalje. Na

varijablu osobne potrošnje, od preostalih varijabli u sustavu, najveći utjecaj ima varijabla NOPI4 čije kretanje može pojasniti čak 15% varijance prognostičke greške varijable DLCONS.

Kako bi se odgovorilo na pitanje koji je pokazatelj cijene nafte (a samim time i procijenjeni VAR model) primjereniji, uspoređeni su korigirani koeficijenti determinacije CONS jednadžbi procijenjenih VAR modela (prikazani Tablicom 4.4.4.10.), a potom i informacijski kriteriji istih (prikazani Tablicom 4.4.4.11.).

Tablica 4.4.4.10.: Korigirani koeficijenti determinacije CONS jednadžbi procijenjenih VAR sustava

Model s pokazateljem:	$\overline{R}^2$
LOIL	0,534208
MORK+/MORK-	0,534906
SOPI/SOPD	0,544580
NOPI4	**0,572513**

Izvor: Izračun autorice

Prikazani rezultati ne upućuju na istovjetan zaključak. Dok korigirani koeficijent determinacije (koji se generalno smatra boljim pokazateljem) implicira VAR sustav s NOPI4 pokazateljem kao superioran, AIC i SBC informacijski kriteriji sugeriraju modele s DLOIL odnosno SOPI/SOPD pokazateljem kao optimalne. S obzirom na praksu prilikom empirijske provjere prethodnih hipoteza gdje se inzistiralo da minimalno dva od tri kriterija upućuju na isti pokazatelj, ovdje su različiti analitički alati ukazali na različite pokazatelje nafte, zbog čega rezultati nisu konkluzivni.

Tablica 4.4.4.11..: Vrijednost Akaike (AIC) i Schwarz (SBC) informacijskih kriterija CONS jednadžbi procijenjenih VAR sustava

Model s pokazateljem:	AIC	SBC
LOIL	-6,745253	**-6,539401**
MORK+/MORK-	-6,732512	-6,492352
SOPI/SOPD	**-6,753532**	-6.513372
NOPI4	-6,742878	-6.254198

Izvor: Izračun autorice

U svakom slučaju, jedini model koji je ukazao na eventualni, i to granično statistički značajan (uz signifikantnost od 10%), negativan utjecaj cijena nafte na osobnu potrošnju je onaj s NOPI4 pokazateljem koji, po svojoj definiciji, podrazumijeva samo rast cijena nafte i to kada do istih dolazi nakon izvjesnog vremena relativno stabilnih cijena (važnost se pridaje efektu iznenađenja). Temeljem svega iznesenog, empirijska provjera hipoteze upućuje na zaključak o nepostojanju nedvojbenog utjecaja cijena nafte na osobnu potrošnju, odnosno, prezentirani

ekonometrijski rezultati sugeriraju **odbacivanje hipoteze H4:** *promjene cijena nafte statistički značajno negativno utječu na kretanje osobne potrošnje.*

4.4.5. Reakcija investicija na promjene cijena nafte

S ciljem testiranja hipoteze *H5: Promjene cijena nafte statistički značajno utječu na kretanje investicija*, općim oblikom VAR modela (4.4.) obuhvaćene su tromjesečne varijable Zt vektora, za period 1996:Q1-2015:Q4; *LINV* – prirodni logaritam realnih investicija (u stalnim cijenama 2010.), *LBDP* - prirodni logaritam realnog bruto domaćeg proizvoda (u stalnim cijenama 2010.), *IRr* – realna kamatna stopa, *LOIL* - prirodni logaritam realne cijene nafte (odnosno pripadajući pokazatelj cijene nafte; *LOIL, MORK+, MORK-, SOPI, SOPD, NOPI4*) i dummy varijabla - *KRIZA*.

Rezultati inicijalno provedenih testova jediničnog korijena nad korištenim vremenskim nizovima sumirani su unutar Tablice 4.4.5.1.

Tablica 4.4.5.1.: Rezultati testova jediničnog korijena za korištene vremenske nizove, tromjesečni podaci (1996:Q1-2015:Q4)

	Model s konstantom i trendom			Model s konstantom			Model bez konstante	
	ADF	PP	KPSS	ADF	PP	KPSS	ADF	PP
LOIL	0,65	0,87	0,16**	-1,73	-1,59	1,01***	0,01	0,74
DLOIL	**-6,45*****	**-6,63*****	**0,09**	**-6,69*****	**-6,59*****	**0,23**	**-6,74*****	**-6,64*****
MORK+	**-6,69*****	**-6,53*****	**0,09**	**-6,63*****	**-6,49*****	**0,29**	**-4,89*****	**-4,84*****
MORK-	**-6,97*****	**-6,97*****	**0,07**	**-6,96*****	**-6,96*****	**0,12**	**-5,71*****	**-5,73*****
SOPI	**-8,79*****	**-8,79*****	**0,07**	**-8,82*****	**-8,82*****	**0,11**	**-8,73*****	**-8,73*****
SOPD	**-8,46*****	**-8,46*****	**0,05**	**-8,46*****	**-8,46*****	**0,11**	**-7,16*****	**-7,25*****
NOPI4	**-5,96*****	**-5,96*****	**0,07**	**-5,80*****	**-5,85*****	**0,22**	**-4,80*****	**-4,80*****
LINV	-1,61	-1,65	0,27***	-2,56	-2,52	0,75***	1,30	1,19
DLINV	**-10,82*****	**-10,60*****	**0,06**	**-10,27*****	**-10,17*****	**0,39***	**-10,08*****	**-10,03*****
LBDP	-0,86	-0,99	0,28***	-2,27	-2,38	0,95***	1,95	2,00
DLBDP	**-11,33*****	**-11,20*****	**0,09**	**-10,69*****	**-10,51*****	**0,52****	**-3,88*****	**-10,11*****
IRr	**-5,27*****	**-5,26*****	**0,20****	**-5,37*****	**-5,34*****	**0,71****	**-5,30*****	**-5,27*****

*,**,*** indicira statistički značajan rezultat na razini od, redom; 10%, 5%, 1%.
Izvor: Izračun autorice

Kao što je bio slučaj i prilikom testiranja prethodnih hipoteza istraživanja, prirodni logaritam realne cijene nafte nije stacionaran u razini, zbog čega je u daljnjem testiranju korištena njegova prva diferencija. Preostali pokazatelji cijena nafte: MORK+, MORK-, SOPI, SOPD i NOPI4, stacionarni su u razinama ili I(0). Varijable realnog BDP-a (*LBDP*) kao i realnih investicija (*LINV*) također su stacionarne tek nakon diferenciranja, dok je varijabla realne kamatne stope

(*IRr*) stacionarna u razini, odnosno integrirana reda nula (I(0)).Temeljem iznijetih rezultata testova jediničnog korijena, daljnja analiza se nastavlja korištenjem stacionarnih vremenskih nizova: *DLINV* (prva diferencija prirodnog logaritma realnih investicija), *DLBDP* (prva diferencija prirodnog logaritma realnog BDP-a), *IRr* (realna kamatna stopa) te stacionarnih pokazatelja cijena nafte; *DLOIL, MORK+, MORK, SOPI, SOPD i NOPI4*.

Slijedi provjera postavljene hipoteze H5 ekonometrijskom procjenom 4 VAR sustava jednadžbi ovisno o tome koji je pokazatelj cijene nafte korišten. Svi sustavi obuhvaćaju varijable realnih investicija, realnog BDP-a i realne kamatne stope (kao i dihotomnu dummy varijablu KRIZA koja se u model uključuje kao egzogena varijabla), dok se u sustav redom permutiraju pokazatelji cijena nafte: 1) realna cijena nafte (točnije prva diferencija prirodnog logaritma iste - DLOIL), 2) MORK+ i MORK-, 3) SOPI i SOPD i 4) NOPI4. Kako varijable kojima se konstruiraju VAR modeli ni u jednoj iteraciji (netom navedene opcije 1 - 4) nemaju isti red integracije (jer je varijabla realne kamatne stope I(0)), u ovom slučaju nije izvršena provjera postojanja kointegracije.

U daljnjem postupku analize, provedeno je testiranje optimalnog broja vremenskih odmaka (u ovom slučaju tromjesečja). Tablica 4.4.5.2. prikazuje konačno odabrane brojeve vremenskih odmaka za procijenjene VAR modele. Broj vremenskih odmaka, 7 tromjesečja, istovjetan je kod svih modela osim onog sa SOPI/SOPD pokazateljima kod kojeg je (zbog problema autokorelacije) odabran VAR model sa 6 vremenskih odmaka.

Tablica 4.4.5.2.: Konačan broj vremenskih odmaka u procijenjenim VAR modelima

Pokazatelj cijena nafte	DLOIL	MORK+/MORK-	SOPI/SOPD	NOPI
Broj vremenskih odmaka procijenjenog VAR sustava (k)	7	7	6	7

Izvor: Izračun autorice

U sljedećem je koraku ekonometrijske analize izvršena i dijagnostička provjera procijenjenih VAR modela, prvenstveno provjera postojanja problema autokorelacije, a potom i problema heteroskedastičnosti kao i provjera oblika distribucije reziduala. Rezultati navedenih testova za sve procijenjene modele prikazani su u sklopu Priloga 2. Također, testirana je i stabilnost svih procijenjenih modela (vidjeti Prilog 2), pri čemu rezultati analize upućuju na zaključak da su svi procijenjeni VAR modeli stabilni.

Nadalje, korištenjem stacionarnih vremenskih nizova, proveden je Granger test uzročnosti u multivarijantnom okruženju. Rezultati istog prikazani su unutar Tablice 4.4.5.3. Granger uzročnost u smjeru od pokazatelja cijena nafte prema realnim investicijama uočena je, na razini od 5% odnosno 10% signifikantnosti (navedenim redoslijedom), kod DLOIL te kod SOPD pokazatelja, što se u ovoj fazi ne može smatrati nepobitnim dokazom utjecaja cijena nafte na realne investicije. Kod preostalih procijenjenih VAR modela Granger test uzročnosti nije pokazao Granger uzročnost u smjeru od cijena nafte (neovisno o načinu njihova iskazivanja) prema realnim investicijama.

Tablica 4.4.5.3.: Prikaz statistički značajnih rezultata Granger uzročnosti procijenjenih VAR modela, multivarijantni okvir

VAR model s pokazateljem:	Detektirani smjer Granger uzročnosti
DLOIL	**DLBDP => DLINV*** **
	IRr => DLINV* **
	DLOIL => DLINV**
	DLINV => DLBDP**
	IRr => DLBDP* **
	DLOIL => DLBDP* **
	DLOIL => IRr**
MORK+/MORK-	**DLBDP => DLINV*** **
	IRr => DLINV* **
	DLINV => DLBDP* **
	IRr => DLBDP* **
	MORK- => DLBDP* **
	MORK+ => DLBDP* **
SOPI/SOPD	**DLBDP => DLINV*** **
	IRr => DLINV* **
	SOPD => DLINV*
	DLINV => DLBDP* **
	IRr => DLBDP* **
	SOPD => DLBDP*
	DLINV => IRr**
	SOPI => IRr* **
	SOPD => IRr**
NOPI4	**DLBDP => DLINV*** **
	IRr => DLINV* **
	IRr => DLBDP* **
	NOPI4 => DLBDP*

*, ** označavaju statistički značajan rezultat uz nivo signifikantnosti od, redoslijedno 10%, 5%.
Izvor: Izračun autorice

Promatranjem ostalih veza unutar procijenjenih VAR sustava može se istaknuti nekoliko konzistentnih rezultata. Tako se kod svih procijenjenih VAR modela, uz 1% signifikantnosti, javlja Granger uzročnost u smjeru od realnog BDP-a, kao i od (teorijski očekivano) realne kamatne stope prema realnim investicijama. Štoviše, kod VAR modela sa MORK+/MORK- i SOPI/SOPD pokazateljima evidentirana je obostrana Granger uzročnost između realnog BDP-

a i realnih investicija. Također, u svim je procijenjenim modelima, uz 1% signifikantnosti, uočena i Granger uzročnost u smjeru od realne kamatne stope prema realnom BDP-u. Kroz definirane VAR modele je, uz različite razine signifikantnosti, prisutna i Granger uzročnost u smjeru od cijena nafte (kod svih pokazatelja cijena nafte osim SOPI) prema realnom BDP-u što potvrđuje rezultate ranije provedene empirijske provjere hipoteze H1.

Kako bi se ispitalo utječu li cijene nafte na realne investicije neposredno, korištenjem Wald testa, testirane su sljedeće hipoteze:

H_0: Koeficijenti pokazatelja cijena nafte jednaki su nuli u INV jednadžbi promatranog VAR sustava jednadžbi.
H_1: Koeficijenti pokazatelja cijena nafte nisu jednaki nuli u INV jednadžbi promatranog VAR sustava jednadžbi.

Rezultati su prikazani Tablicom 4.4.5.4. Rezultati provedenih Wald testova nad procijenjenim parametrima VAR sustava impliciraju prihvaćanje H_1 samo kod VAR sustava s realnom cijenom nafte. Pri tome rezultati upućuju na zaključak da su u dotičnom VAR sustavu koeficijenti koji se u jednadžbi realnih investicija nalaze ispred pokazatelja cijena nafte (DLOIL) statistički značajno različiti od nule (uz 5% signifikantnosti). Ipak, rezultati Wald testa kod preostalih VAR sustava upućuju na prihvaćanje nulte hipoteze čime sugeriraju zaključak oprečan prethodno iznijetom.

Tablica 4.4.5.4.: Rezultati Wald testa – bivarijantni okvir

DLOIL	MORK+	MORK-	SOPI	SOPD	NOPI4
0,0407**[184]	0,2322	0,1824	0,3361	0,1620	0,1233

p vrijednosti hi kvadrat distribucije. Podebljane vrijednosti unutar ćelija označavaju statistički značajan rezultat na razini od 1%, 5% ili 10%, redoslijedno: ***,**,*.
Izvor: Izračun autorice

Kako bi se procijenilo utječu li možda cijene nafte na realne investicije posredno putem preostalih odabranih varijabli u modelu (realnog BDP-a i/ili realne kamatne stope), testirana je i statistička značajnost pokazatelja cijena nafte u kontekstu cjelokupnih procijenjenih VAR sustava. Konkretno, Wald testom su testirane sljedeće hipoteze:

[184] p vrijednosti hi-kvadrat distribucije za odabrane modele

H_0: Koeficijenti pokazatelja cijena nafte su jednaki nuli u svim jednadžbama procijenjenog VAR sustava osim u jednadžbi cijene nafte i INV jednadžbi.
H_1: Koeficijenti pokazatelja cijena nafte nisu jednaki nuli u svim jednadžbama procijenjenog VAR sustava osim u jednadžbi cijene nafte i INV jednadžbi.

Rezultati Wald testa, prikazani Tablicom 4.4.5.5., ukazuju na statistički značajan utjecaj cijena nafte na preostale varijable u VAR sustavu (odbacivanje H_0) na razini od 1% signifikantnosti s izuzetkom kod NOPI4 gdje je signifikantnost rezultata 10%. Ovakav je rezultat donekle i očekivan kada se u obzir uzmu prethodno izneseni rezultati Granger testa uzročnosti koji su upućivali na Granger uzročnost u smjeru od cijena nafte prema realnom BDP-u, odnosno u smjeru od cijena nafte prema kamatnoj stopi.

Tablica 4.4.5.5.: Rezultati Wald testa – multivarijantni okvir

DLOIL	MORK+	MORK-	SOPI	SOPD	NOPI4
0,0000****	**0,0030*****	**0,0001*****	0,0190**	**0,0093*****	0,0708*

p vrijednosti hi kvadrat distribucije. Podebljane vrijednosti unutar ćelija označavaju statistički značajan rezultat na razini od 1%, 5% ili 10%, redoslijedno: ***,**,*.
Izvor: Izračun autorice

U nastavku je, korištenjem Wald testa, ispitano jesu li pozitivni i negativni koeficijenti pokazatelja cijena nafte jednaki u jednadžbama procijenjenih VAR modela, odnosno postoji li statistički značajna razlika između pokazatelja koji se odnose na pozitivne promjene cijena nafte (MORK+ i SOPI) i pokazatelja koji se odnose na negativne promjene cijena nafte (MORK- i SOPD). Rezultati provedenog Wald testa indiciraju prihvaćanje, odnosno odbacivanje hipoteza:

H_0: Pozitivni i negativni koeficijenti pokazatelja cijena nafte u INV jednadžbi odnosno u preostalim jednadžbama promatranog VAR sustava su jednaki.
H_1: Pozitivni i negativni koeficijenti pokazatelja cijena nafte u INV jednadžbi odnosno u preostalim jednadžbama promatranog VAR sustava nisu jednaki.

Rezultati analize prikazani su Tablicom 4.4.5.6. pri čemu se iz prikazanih rezultata može zaključiti da u jednadžbi realnih investicija ne postoji statistički značajna razlika u visini procijenjenih pozitivnih i negativnih koeficijenata promjena cijena nafte. Naime, rezultat za SOPI/SOPD nije statistički značajan, a za MORK+/MORK- je tek granično statistički značajan (uz razinu pouzdanosti od 10%). S druge strane, ako se sagledaju preostale jednadžbe

procijenjenih VAR sustava, Wald test implicira statistički značajnu razliku u utjecaju pozitivnih i negativnih pokazatelja cijena nafte na preostale varijable u sustavu, i to na razini od 1%, kako kod MORK+/MORK- tako i kod SOPI/SOPD pokazatelja. Navedeno se opet može dovesti u vezu s prethodno iznesenim rezultatima Granger uzročnosti. Važno je, pri tom, istaknuti da navedeni rezultati ne ukazuju na smjer kao ni na intenzitet veze između cijena nafte i ostalih varijabli u procijenjenim VAR sustavima.

Tablica 4.5.5.6.: Rezultati Wald testa jednakosti procijenjenih parametara pokazatelja pozitivnih i negativnih promjena cijena nafte

MORK+ = MORK-		SOPI = SOPD	
INV jednadžba	VAR sustav jednadžbi	INV jednadžba	VAR sustav jednadžbi
0,0759*	**0,0000*** **	0,1804	**0,0000*** **

p vrijednosti hi kvadrat distribucije. Podebljane vrijednosti unutar ćelija označavaju statistički značajan rezultat na razini od 1%, 5% ili 10%, redoslijedno: ***,**,*.
Izvor: Izračun autorice

Detaljnijim sagledavanjem statističke značajnosti pojedinih procijenjenih koeficijenata, analiza je pokazala da se ovakav rezultat Wald testa javlja kao posljedica činjenice da VAR modeli s MORK+/MORK- i SOPI/SOPD pokazateljima (u prva dva tromjesečja nakon šoka) pokazuju statistički značajan pozitivan utjecaj rasta cijena nafte (predstavljenim MORK+ i SOPI pokazateljima) na realni BDP kao i statistički značajan negativan utjecaj pada cijena nafte (predstavljenim MORK- i SOPD pokazateljima) na pad realne kamatne stope.

U sljedećem je koraku analizirana i statistička značajnost dihotomne dummy varijable KRIZA. Rezultati provedene analize, sažeti Tablicom 4.5.5.7., ukazuju na činjenicu da kriza utječe na sve odabrane varijable (i u svim procijenjenim VAR modelima na isti način, što potvrđuje njihovu dobru definiranost) i to: statistički značajno negativno na realne investicije (uz 5% signifikantnosti), statistički značajno negativno na realni BDP (uz 1% signifikantnosti), odnosno statistički značajno pozitivno na realnu kamatnu stopu (uz 5% signifikantnosti)[185].

Grafikonom 4.5.5.1. prikazane su funkcije impulsnog odziva varijabli u sustavu pri čemu je šok u sustavu jednadžbi definiran kao promjena pokazatelja cijena nafte (DLOIL, MORK+, MORK-, SOPI, SOPD i NOPI4) u visini jedne standardne devijacije. Kod VAR modela s

[185] S iznimkom kod modela s NOPI4 pokazateljem cijena nafte gdje se utjecaj NOPI4 na realnu kamatnu stopu nije pokazao statistički značajnim.

realnom cijenom nafte funkcija impulsnog odziva pokazuje pozitivan utjecaj varijable DLOIL na realne investicije u prva dva tromjesečja nakon inicijalnog šoka (+ 1% na šok od 1 S.D.). Gotovo identična reakcija realnih investicija, točnije varijable DLINV, je i kod pokazatelja NOPI4, MORK+ i SOPD. Jednako tako, u 5. odnosno 6. tromjesečju nakon šoka pokazatelja cijena nafte, evidentan je statistički značajan negativan utjecaj cijena nafte na investicije (cca 2% u prosjeku na šok od 1 S.D.) i to kod DLOIL, MORK+, SOPI i SOPD.

Tablica 4.4.5.7.: Statistička značajnost dummy varijable KRIZA

Model s pokazateljem:	Utjecaj varijable KRIZA na:	Vrijednost procijenjenog parametra:
DLOIL	DLINV	-0,060928**
	DLBDP	**-0,045698*** **
	IRr	2,874627**
MORK+/MORK-	DLINV	-0,056515**
	DLBDP	**-0,045206*** **
	IRr	2,788253*
SOPI/SOPD	DLINV	-0,059027**
	DLBDP	**-0,034751*** **
	IRr	2,554073**
NOPI4	DLINV	-0,047558*
	DLBDP	**-0,032665*** **
	IRr	1,735330

*,**,*** indicira statistički značajan rezultat na razini od, redom; 10%, 5%, 1%.
Izvor: Izračun autorice

Ovdje je posebno zanimljiva reakcija realnih investicija na SOPI i SOPD gdje je utjecaj šoka u navedenim varijablama negativan u oba slučaja. To govori u prilog tezi da rast neizvjesnosti (volatilnosti) smanjuje investicije neovisno o tome jesu li cijene nafte padale ili rasle. Pozornost bi bilo uputno usmjeriti na pokazatelj DLOIL kod kojeg je prethodno detektirana Granger uzročnost u smjeru prema realnim investicijama. Također se može konstatirati da, za razliku od procijenjenih VAR sustava prethodnih analiza, unutar prikazanog vremenskog perioda nije vidljivo smirivanje funkcije (stapanje granica ± 2 SD s funkcijom impulsnog odziva), a što se može dovesti u vezu s većim brojem odabranih vremenskih odmaka (k=7, odnosno k=6) procijenjenih VAR sustava jednadžbi.

Grafikon 4.4.5.1.: Impulsne funkcije odziva varijable DLINV na šok od jedne standardne devijacije u varijablama koje predstavljaju pokazatelje cijena nafte u svim procijenjenim VAR modelima

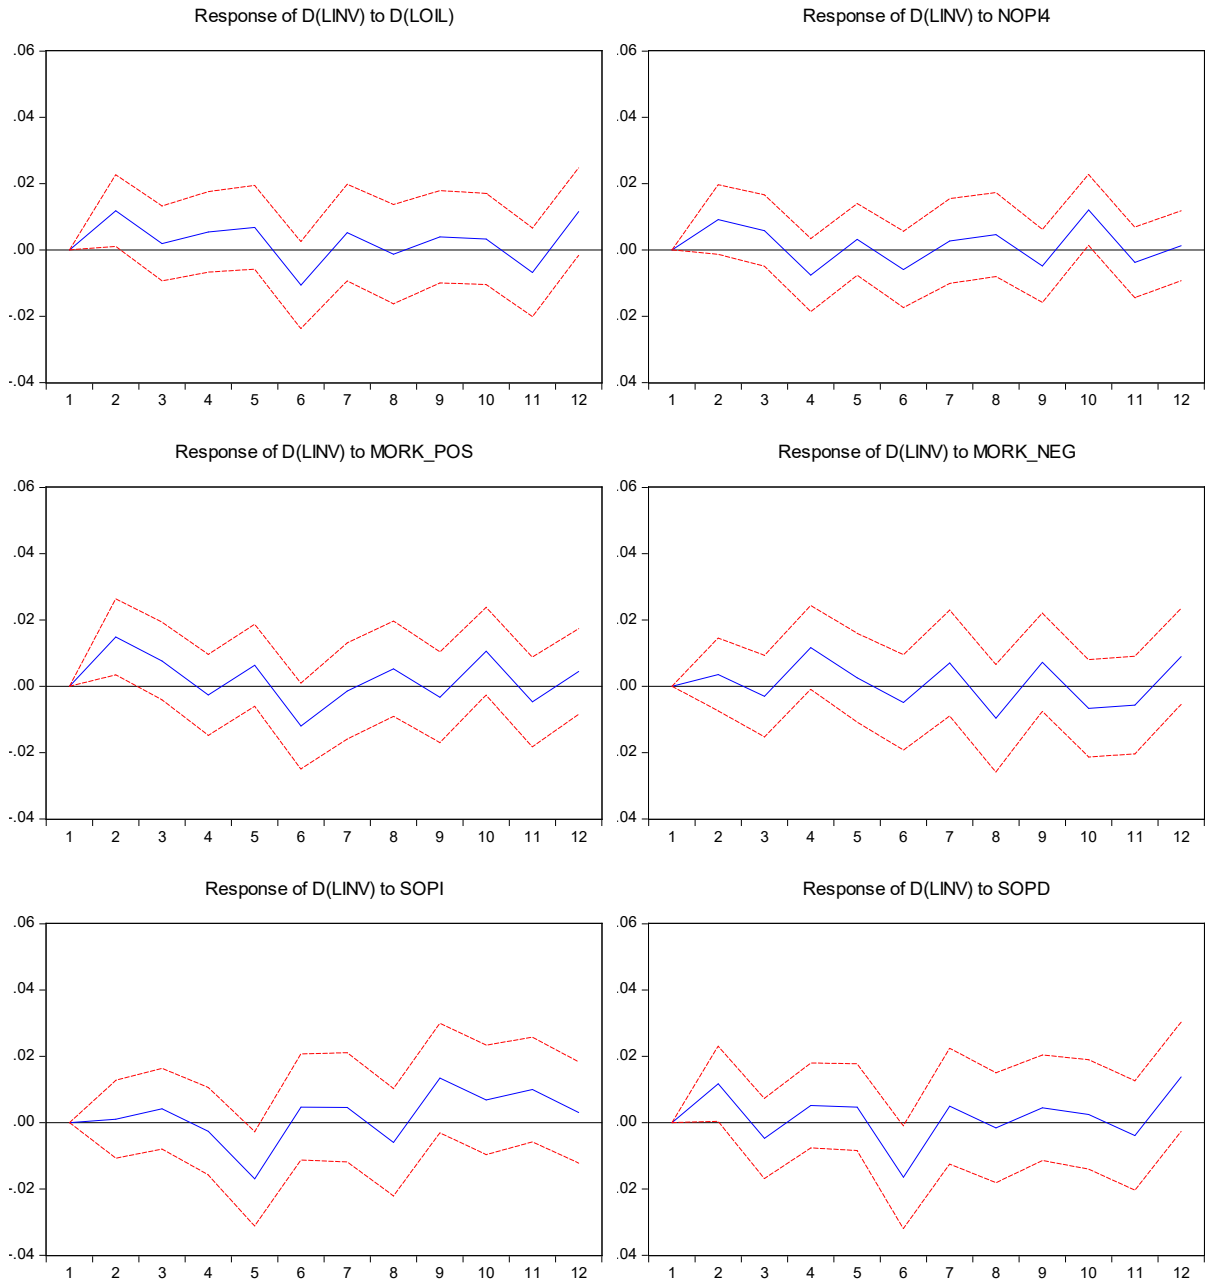

*Pune plave linije predstavljaju funkcije, isprekidane crvene linije odstupanje od dvije standardne devijacije (interval pouzdanosti procjene 95%), na ordinati su razine pojave izražene u mjernim jedinicama varijable, a na apscisi vrijeme izraženo u tromjesečjima.
Izvor: Izračun autorice

Podaci u Tablici 4.4.5.8. prikazuju rezultate dekompozicije varijance prognostičke greške za procijenjene jednadžbe realnih investicija (*DLINV*). Dekompozicija se odnosi na period od tri godine (12 tromjesečja) i to na način da je ista razložena na doprinos pojedine varijable u sustavu ukupnoj varijanci prognostičke greške varijable realnih investicija. Može se istaknuti (što nije bio slučaj u dosadašnjim procjenama VAR sustava jednadžbi) da najkasnije od osmog

tromjesečja navedeni udio pada ispod 50% što bi značilo da se prevladavajući dio varijabilnosti varijable realnih investicija ne može protumačiti prethodnim kretanjem same varijable, već preko ostalih varijabli u sustavu. Ipak, ovdje je fokus na utjecaj kretanja cijena nafte na realne investicije, odnosno na pitanje koliki je udio prognostičke greške istih u pojašnjavanju prognostičke greške varijable realnih investicija (DLINV).

Dekompozicija varijance varijable realnih investicija pokazuje da je najveći dio varijacija analizirane varijable kroz vrijeme moguće objasniti vlastitom prognostičkom greškom, iako valja naznačiti da navedeni udio (što nije bio slučaj kod preostalih analiziranih makroekonomskih pokazatelja u ovom istraživanju) rapidno opada na svega 40% koncem promatranog perioda. Na varijancu varijable realnih investicija, od preostalih varijabli u VAR sustavu, najveći utjecaj ima varijabla realnog BDP-a koja kod pojedinih modela pojašnjava čak do 30% varijabilnosti realnih investicija, a potom i cijene nafte čije kretanje u prosjeku može pojasniti značajnih 15% do 20% varijance prognostičke greške varijable realnih investicija. Ipak nužno je naznačiti da unutar ranijih perioda cijene nafte pojašnjavaju veći udio varijance realnih investicija, a taj udio tek kasnije preuzima kretanje BDP-a.

Kod pokazatelja MORK+/MORK- i SOPI/SOPD zbirni se udio utjecaja cijena nafte penje čak i do 35%, te time i ukupno nadilazi udio kretanja BDP-a u pojašnjavanju varijance prognostičke greške realnih investicija. Ipak, vodeći se rezultatima dekompozicije varijance u odnosu na DLOIL i NOPI4, kod kojih su i testiranje Granger uzročnosti i IRF-ova ukazali na statistički značajan utjecaj cijena nafte na realne investicije, udio istih u pojašnjavanju varijance prognostičke greške varijable DLINV penje se do nekih 15%, što je i dalje respektabilan udio.

Tablica 4.4.5.8.: Dekompozicije varijance varijable DLINV

Period	S.E.	D(LINV)	D(LBDP)	IRR	**D(LOIL)**
1	0.035872	100.0000	0.000000	0.000000	**0.000000**
2	0.038531	86.95240	3.317852	0.277431	**9.452318**
4	0.041963	73.31423	12.13177	4.691981	**9.862020**
6	0.051439	49.39116	26.49774	11.56520	**12.54590**
8	0.054349	46.93960	28.66798	12.17357	**12.21886**
12	0.057214	43.85968	26.78741	12.03179	**17.32111**
Period	S.E.	D(LINV)	D(LBDP)	IRR	**NOPI4**
1	0.036981	100.0000	0.000000	0.000000	**0.000000**
2	0.038562	92.22535	1.844235	0.299804	**5.630612**

4	0.043119	74.48182	12.76917	3.295549	**9.453465**
6	0.051382	53.65274	29.12469	8.863320	**8.359253**
8	0.053964	51.37720	29.67684	10.37816	**8.567795**
9	0.054602	50.96977	29.57542	10.29584	**9.158969**
10	0.056832	49.73808	27.42421	9.879108	**12.95860**
12	0.057636	48.70068	26.77304	11.45470	**13.07158**

Period	S.E.	D(LINV)	D(LBDP)	IRR	**MORK_POS**	MORK_NEG
1	0.036125	100.0000	0.000000	0.000000	**0.000000**	0.000000
2	0.040039	82.85398	2.512211	0.029006	**13.82421**	0.780596
4	0.043918	68.96153	5.580692	2.400766	**14.85639**	8.200624
6	0.052858	47.89654	20.88416	7.640025	**16.82553**	6.753751
8	0.056290	44.79496	21.54168	7.438323	**15.78075**	10.44428
10	0.060101	43.70295	19.13231	8.072262	**17.25254**	11.83994
12	0.061533	41.88137	18.41103	7.856421	**17.57689**	14.27428

Period	S.E.	D(LINV)	D(LBDP)	IRR	**SOPI**	**SOPD**
1	0.036403	100.0000	0.000000	0.000000	**0.000000**	**0.000000**
2	0.038944	87.38182	3.418356	0.073600	**0.067995**	**9.058227**
4	0.042070	75.99332	8.216927	3.817796	**1.434634**	**10.53732**
5	0.048128	61.10164	9.542360	6.886726	**13.48010**	**8.989169**
6	0.055696	45.67412	20.83000	7.283322	**10.77750**	**15.43506**
8	0.058512	44.10031	22.69757	7.008141	**11.41563**	**14.77835**
10	0.061932	41.88645	20.70225	7.420545	**16.11854**	**13.87222**
12	0.064751	39.08821	18.95025	7.014712	**17.34923**	**17.59760**

Izvor: Izračun autorice

Treba imati na umu i posredan utjecaj cijena nafte na investicije kroz utjecaj realnog BDP-a na investicije. Ako se izuzme udio varijance vlastite prognostičke pogreške, cijene nafte su se i kod testiranja hipoteze H1 (a vrlo slični su rezultati i ovdje) pokazale kao primarni izvor varijabilnosti varijable realnog BDP-a (među preostalim odabranim varijablama modela).

Konačno, uspoređeni su procijenjeni modeli s ciljem identificiranja najprimjerenijeg pokazatelja cijena nafte. U tu svrhu uspoređeni su korigirani koeficijenti determinacije INV jednadžbi procijenjenih VAR modela (prikazani Tablicom 4.4.5.9.), a potom i Akaike i Schwarz informacijski kriteriji istih (prikazani Tablicom 4.4.5.10.).

Tablica 4.4.5.9.: Korigirani koeficijenti determinacije INV jednadžbi procijenjenih VAR sustava

Model s pokazateljem:	$\bar{R}^2$
LOIL	**0,580836**
MORK+/MORK-	0,574891
SOPI/SOPD	0,568337
NOPI4	0,554512

Izvor: Izračun autorice

Najviši korigirani koeficijent determinacije detektiran je kod jednadžbe s DLOIL pokazateljem, pri čemu i Akaike i Schwarz informacijski kriteriji upućuju na istovjetan zaključak. To potvrđuje rezultate analize Granger uzročnosti te upućuje na korištenje navedenog pokazatelja kao najprimjerenijeg u procjeni utjecaja cijena nafte na realne investicije.

Tablica 4.4.5.10.: Vrijednost Akaike (AIC) i Schwarz (SBC) informacijskih kriterija INV jednadžbi procijenjenih VAR sustava

Model s pokazateljem:	AIC	SBC
LOIL	**-3,525068**	**-2,583784**
MORK+/MORK-	-3,496887	-2,335969
SOPI/SOPD	-3,488521	-2,484484
NOPI4	-3,464162	-2,522877

Izvor: Izračun autorice

Rast cijena nafte, iskazan pokazateljem DLOIL, u prva dva tromjesečja nakon promjene ima pozitivan utjecaj na realne investicije, koji nakon toga prestaje biti statistički značajan do šestog tromjesečja u kojem postaje negativan (čime se neutralizira pozitivan utjecaj s početka razdoblja nakon inicijalnog šoka).

Uvažavajući izneseno može se konstatirati da realne investicije inicijalno statistički značajno pozitivno reagiraju na promjene cijena nafte, stoga empirijski rezultati upućuju na **prihvaćanje hipoteze H5**: *Promjene cijena nafte statistički značajno utječu na kretanje investicija.*

4.4.6. Asimetričnost utjecaja cijene nafte na cijene naftnih derivata

Kako je već elaborirano kroz razradu teme doktorske disertacije, istraživanja utjecaja cijena nafte na makroekonomske pokazatelje (prvenstveno na gospodarski rast) uglavnom kao input koriste cijene nafte kao što je, zbog usporedivosti, slučaj i kod ovog istraživanja. S druge strane, tek se zanemariv dio potrošnje nafte na nacionalnoj razini troši u nerafiniranom obliku jer krajnji potrošači konzumiraju derivate nafte. Ovdje je važno napomenuti da neke zemlje uvoze isključivo naftne derivate jer ne posjeduju nikakve rafinerijske kapacitete. U Hrvatskoj to nije slučaj, kao što je elaborirano u poglavlju 3.6., iako se omjer uvezene sirove nafte kontinuirano smanjuje u korist uvoza (gotovih) naftnih derivata, a što je posljedica sve manje proizvodnje hrvatskih rafinerija nafte. Ipak činjenica je da se na maloprodajnom tržištu naftni derivati kupuju po cijenama koje bi trebale, ali ne moraju (ili ne moraju jednakom brzinom) odražavati stvarnu sliku kretanja svjetskih cijena nafte.

Imajući izneseno u vidu hipoteza *H6: Cijene naftnih derivata asimetrično reagiraju na promjenu cijene nafte,* ima za cilj provjeriti odnos kretanja cijena sirove nafte na svjetskom tržištu u odnosu na maloprodajne cijene najprodavanijih naftnih derivata na domaćem tržištu. Također, empirijska provjera je koncipirana na način da se istraži eventualno postojanje cjenovne asimetrije, odnosno procijeni brzina prilagodbe cijena naftnih derivata na cijene nafte uslijed promjene (pada, odnosno rasta) svjetskih cijena nafte. Time se želi ustanoviti iskorištavaju li poslovni subjekti na domaćem maloprodajnom tržištu naftnih derivata promjene cijena sirove nafte kako bi im se prilagodili sporijim tempom uslijed pada cijena nafte nego li je to slučaj uslijed njihova rasta.

Kako je evidentno iz podataka ranije prikazanih Grafikonom 3.6.6., više od 90% ukupne potrošnje naftnih derivata odnosi se na dizelska i motorna goriva. Zbog toga će za provjeru postavljene hipoteze, a u skladu s usporedivim istraživanjima, biti korištene prosječne mjesečne maloprodajne cijene Eurodizela i Eurosuper 95 i to bez poreza i trošarina[186]. Razlog zbog kojeg su korištene cijene bez poreza i trošarina, što je slučaj i kod usporedivih istraživanja cjenovne asimetrije na tržištima naftnih derivata (*cf. Galeotti et al., 2003; Liu et al., 2010; Radchenko, 2005b*), nužan je zbog eliminiranja utjecaja poreza i trošarina na krajnje cijene naftnih derivata. Na tragu navedenog pojašnjena je važna uloga poreza i trošarina na naftne derivate na njihovu maloprodajnu cijenu (cf. Poglavlje 3.6.2.). Ipak, porezi i trošarine i njihove oscilacije u stvarnosti ne moraju imati, a uglavnom ni nemaju, veze s kretanjima cijena nafte na svjetskom tržištu. Ovdje je fokus na reakcije maloprodajnih cijena naftnih derivata na promjene cijena nafte kako bi se detektirala reakcija poslovnih subjekata koji naftne derivate plasiraju na domaće maloprodajno tržište. Europske države imaju izrazito visok udio poreza i trošarina u krajnjoj cijeni naftnih derivata (promatrano na globalnoj razini), a „krpanje“ proračunskih rupa nerijetko bude motiv vladajućim strukturama za iskorištavanje cjenovno neelastičnog karaktera potražnje za naftnim derivatima.

U provjeri hipoteze H6 korištene su prosječne mjesečne maloprodajne cijene Eurodizela i Eurosuper 95 bez poreza i trošarina za period od siječnja 2000. do prosinca 2015 (vremenski nizovi od po 192 podatka) u kunama po litri, kao i nominalna cijena nafte u kunama po litri pri

[186] Eurodizel je na hrvatsko tržište uveden 2001. godine pri čemu su za prethodno razdoblje korištene cijene INA dizel goriva (INA DG). Eurosuper 95 uveden je na hrvatsko tržište 2004. godine, a za prethodno su razdoblje korištene cijene INA bezolovnog motornog benzina 95 (INA BMB 95). U oba slučaja riječ je o INA-inim prosječnim cijenama što se može smatrati relevantnim nacionalnim prosjekom s obzirom na veliki udio INA-e u ukupnom tržišta maloprodaje naftnih derivata u Republici Hrvatskoj.

čemu je konverzija izvršena temeljem HNB-ovog srednjeg tečaja kune u odnosu na USD odnosno temeljem konverzijskog faktora prema kojem jedan barel sadrži 158,987 litara nafte.

Temeljem rezultata provedenih testova jediničnog korijena, prikazanih Tablicom 4.4.6.1., može se zaključiti da su promatrani vremenski nizovi, prirodni logaritmi cijena nafte kao i naftnih derivata Eurodizel i Eurosuper 95, nestacionarni, odnosno da su njihove prve diferencije stacionarne. Drugim riječima, varijable su integrirane reda jedan ili I(1).

Tablica 4.4.6.1.: Rezultati testova jediničnog korijena za korištene vremenske nizove, tromjesečni podaci (2000:M01-2015:M12)

	Model s konstantom i trendom			Model s konstantom			Model bez konstante	
	ADF	PP	KPSS	ADF	PP	KPSS	ADF	PP
LOIL	-1,68	-1,52	0,15**	-1,74	-1,80	1,30***	-0,72	-0,65
DLOIL	**-11,92*** **	**-11,80*** **	**0,08**	**-11,89*** **	**-11,77*** **	**0,18**	**-11,92*** **	**-11,81*** **
LES95	-3,69**	-2,82	0,10	-1,91	-2,22	1,39***	-0,08	0,10
DLES95	**-9,92*** **	**-9,11*** **	**0,05**	**-9,93*** **	**-9,11*** **	**0,13**	**-9,95*** **	**-9,13*** **
LDIESEL	-2,35	-1,91	0,13*	-2,12	-2,22	1,37***	0,05	0,39
DLDIESEL	**-10,18*** **	**-9,96*** **	**0,05**	**-10,13*** **	**-9,92*** **	**0,22**	**-10,13*** **	**-9,94*** **

*,**,*** indicira statistički značajan rezultat na razini od, redom; 10%, 5%, 1%.
Izvor: Izračun autorice

Temeljem provedene ekonometrijske analize (ispitivanja autokorelacije grešaka relacije, heteroskedastičnosti i testiranja kointegracije), kao i analize utjecaja cijena nafte na Eurosuper 95 i Eurodizel, odabrana je duljina pomaka $k = 1$, što je i u skladu s očekivanjima o brzini prilagodbe cijena naftnih derivata cijenama nafte.

U sljedećem je koraku procijenjeno postojanje kointegracije između cijena nafte i cijena naftnih derivata. S ekonomskog stajališta, ako su varijable kointegrirane, tada među njima postoji dugoročan odnos koji se može kvantificirati kointegracijskom jednadžbom. Cijene nafte predstavljaju temeljni input kada se govori o cijenama naftnih derivata; stoga je logično i teorijski postaviti hipotezu da su cijene nafte i cijene naftnih derivata kointegrirane. Nadalje, prethodnom je analizom ustanovljeno da parovi varijabli koje se analiziraju (cijena nafte ↔ Eurodizel, cijena nafte ↔ Eurosuper 95) imaju isti red integracije (I(1)) što je u ekonometrijskom smislu preduvjet za postojanje kointegracije. Postojanje kointegracije testirano je Johansenovim testom čiji su rezultati prikazani Tablicama 4.4.6.2. (za Eurosuper 95) i 4.4.6.3. (za Eurodizel).

Tablica 4.4.6.2.: Rezultati Johansenovog testa kointegracije (varijable: DLOIL, DLES95)

Test traga matrice

H_0: r =	Svojstvena vrijednost	Test veličina	Kritična vrijednost 0,05	Vjerojatnost**
0	**0.111874**	**25.20738**	**15.49471**	**0.0013*** **
1	0.013930	2.665398	3.841466	0.1026

*** označava odbacivanje nulte hipoteze pri razini od 1% značajnosti
**p vrijednosti prema MacKinnon-Haug-Michelis (1999)

Test najveće svojstvene vrijednosti

H_0: r =	Svojstvena vrijednost	Test veličina	Kritična vrijednost 0,05	Vjerojatnost**
0	**0.111874**	**22.54198**	**14.26460**	**0.0020*** **
1	0.013930	2.665398	3.841466	0.1026

*** označava odbacivanje nulte hipoteze pri razini od 1% značajnosti
**p vrijednosti prema MacKinnon-Haug-Michelis (1999)

Izvor: Izračun autorice

U oba slučaja, kod Eurosupera 95 kao i kod Eurodizela, Johansenov test upućuje na postojanje jedne kointegracijskog jednadžbe. Uz razinu signifikantnosti od 1%, provedeni testovi traga matrice i testovi najveće svojstvene vrijednosti upućuju na zaključak da je broj kointegracijskih vektora jednak jedan. Naedeno je u skladu s pretpostavkama modela kao i ekonometrijskim postavkama korištene metodologije koja implicira da je među dvama varijablama (cijena naftnog derivata ⇔ cijena nafte) maksimalan broj kointegracijskih relacija, odnosno jednadžbi, jednak jedan (*Enders, 2010, str. 360*).

Tablica 4.4.6.3.: Rezultati Johansenovog testa kointegracije (varijable: DLOIL, DLDIESEL)

Test traga matrice

H_0: r =	Svojstvena vrijednost	Test veličina	Kritična vrijednost 0,05	Vjerojatnost**
0	**0.133319**	**30.05416**	**15.49471**	**0.0002*** **
1	0.014983	2.868228	3.841466	0.0903

*** označava odbacivanje nulte hipoteze pri razini od 1% značajnosti
**p vrijednosti prema MacKinnon-Haug-Michelis (1999)

Test najveće svojstvene vrijednosti

H_0: r =	Svojstvena vrijednost	Test veličina	Kritična vrijednost 0,05	Vjerojatnost**
0	**0.133319**	**27.18593**	**14.26460**	**0.0003*** **
1	0.014983	2.868228	3.841466	0.0903

*** označava odbacivanje nulte hipoteze pri razini od 1% značajnosti
**p vrijednosti prema MacKinnon-Haug-Michelis (1999)

Izvor: Izračun autorice

Kako bi se ispitao dugoročan odnos cijena nafte i cijena naftnih derivata korišten je model predložen od strane *Liu et al. (2010)*. Temeljem ranije postavljenog oblika jednadžbe dugog roka (4.1.) analiziran je dugoročan odnos cijene Eurosupera 95 i cijena nafte, odnosno cijene Eurodizela i cijena nafte.

Procijenjeni parametri prikazani su Tablicom 4.4.6.4. Dugoročna prilagodba cijena naftnih derivata cijenama nafte je potpuna ako je α_1 jednako 1, a ako je α_1 manje od 1, znači da je prilagodba cijena nepotpuna, što se događa ako tržišta naftnih derivata nisu savršeno konkurentna.

Tablica 4.4.6.4.: Procijenjene vrijednosti parametara u jednadžbi dugog roka

Zavisna varijabla	α_0	α_1
LES95	0,657909***	0,699325***
LDIESEL	0,673449***	0,753830***

Izvor: izračun autorice
*,**,*** indicira statistički značajan rezultat na razini od, redom; 10%, 5%, 1%.

Svi procijenjeni parametri statistički su značajni na razini od 1%. Procijenjena vrijednosti parametra α_1 od 0,699 odnosno 0,754 svjedoči o, očekivanom, nepotpunom prilagođavanju cijena naftnih derivata cijenama nafte. Također, može se uočiti da je vrijednost parametra α_1 viša kod *LDIESEL* što implicira potpuniju prilagodbu cijena dizelskog goriva cijenama nafte negoli je to slučaj kod dugoročne prilagodbe cijena bezolovnog motornog benzina cijenama nafte. Navedene vrijednosti izračunatih parametra su manje od jedan ($\alpha_1 < 1$) što je tipično za nesavršena tržišta na kojima prilagodba cijene nije potpuna. Zaključiti se stoga može da je promatrano tržište po strukturi nesavršeno; stoga je i prilagodba cijena naftnih derivata manja od 100% (69,9% kod Eurosuper 95 i 75,4% kod Eurodizel), odnosno nepotpuna.

U nastavku analize, ranije opisanim modelom korekcije pogreške (4.2.), a uz pomoć reziduala procijenjenih jednadžbi dugog roka, procijenjene su jednadžbe kratkog roka. Tablicom 4.4.6.5. prikazane su vrijednosti procijenjenih koeficijenata. Procijenjeni parametri β_1, kod obiju jednadžbi, statistički su značajni i pozitivni što ukazuje na činjenicu da se ovisno o promjeni cijena nafte i promjene cijena naftnih derivata kreću u istom smjeru. Činjenica da su β_2 koeficijenti negativni i statistički značajni, ponovno potvrđuje (ranije dokazano) postojanje dugoročne veze među varijablama. Parametri β_2 svjedoče o brzini prilagodbe ravnotežnom stanju te kao takvi očekivano imaju negativan predznak. Navedeno ukazuje na periodičku korekciju odstupanja cijena derivata od njihove procijenjene dugoročne razine. Procijenjene

vrijednosti upućuju na zaključak da se u svakom periodu (mjesečno) korigira 32,59% (za Eurosuper95) odnosno 29,38% (za Eurodizel) odstupanja od ravnotežnog stanja, odnosno da se varijable vraćaju u dugoročnu ravnotežu za približno tri mjeseca. Također se može zaključiti da se cijene Eurosupera 95 vraćaju u dugoročnu ravnotežu brže od cijena Eurodizela. Izračun vremenskog odmaka potrebnog za prilagodbu srednjoj vrijednosti (*MAL*), koji se računa po formuli: $MAL = \frac{\beta_1 - 1}{\beta_2}$, nalaže da je za prilagodbu cijena Eurosupera 95 (odnosno vraćanje dugoročnoj ravnoteži) potrebno u prosjeku 1,79 mjeseci, dok je za prilagodbu cijena Eurodizela dugoročnoj ravnoteži potrebno 2,38 mjeseci. Dakle, prilagodba cijena Eurosupera95 je znatno brža u odnosu na Eurodizel.

Tablica 4.4.6.5.: Procijenjene vrijednosti parametara jednadžbi kratkog roka

Zavisna varijabla modela	β_1	β_2
LES95	0,414261***	-0,325904***
LDIESEL	0,299467**	-0,293830***

Izvor: izračun autorice
*,**,*** indicira statistički značajan rezultat na razini od, redom; 10%, 5%, 1%.

U sljedećem je koraku, korištenjem reziduala procijenjenih jednadžbi kratkog roka, procijenjena asimetrična kratkoročna dinamička relacija. U skladu s jednadžbom (4.3.), procijenjeni su, unutar Tablice 4.4.6.6. prikazani, parametri; δ_1, δ_2 i δ_3, pri čemu je parametar δ_1 ekvivalentan prethodno protumačenom parametru β_1. Promatrajući rezultate može se prije svega konstatirati da su svi izračunati koeficijenti statistički značajni na razini od 1%. Ipak, što je važnije, rezultati Wald testa ističu da je razlika u procijenjenim vrijednostima parametara δ_2 i δ_3 kod Eurosupera 95 granično statistički značajna, odnosno statistički značajna uz nivo pouzdanosti od 10%, dok ista kod Eurodizela nije statistički značajna. Ovakav rezultat upućuje na zaključak o odbacivanju hipoteze o asimetričnoj prilagodbi cijena Eurodizela cijenama nafte, odnosno o prihvaćanju iste za cijene Eurosuper 95, ali uz 10% signifikantnosti.

Tablica 4.4.6.6.: Procijenjene vrijednosti parametara asimetričnog modela korekcije grešaka, Wald test omjeri i njihove razine empirijske signifikantnosti

Zavisna varijabla modela	δ_1	δ_2	δ_3	Wald test t-omjer	Empirijska razina signifikantnosti
DLES95	0,413509***	-0,250876***	-0,423008***	1,887633	0,0606*
DLDIESEL	0,298303***	-0,320170***	-0,275765***	-0,679940	0,4974

Izvor: izračun autorice
*,**,*** indicira statistički značajan rezultat na razini od, redom; 10%, 5%, 1%.

Pomak potreban za prilagodbu srednjoj vrijednosti (MAL) u ovoj specifikaciji modela računa se po formuli $MAL^{+} = \frac{\delta_1 - 1}{\delta_2}$, odnosno $MAL^{-} = \frac{\delta_1 - 1}{\delta_3}$, gdje MAL^{+} predstavlja vremenski odmak potreban za prilagodbu srednjoj vrijednosti kada su cijene naftnih derivata iznad ravnotežne vrijednosti (broj mjeseci), a MAL^{-} vremenski odmak potreban za prilagodbu srednjoj vrijednosti kada su cijene naftnih derivata ispod ravnotežne vrijednosti.

U Tablici 4.4.6.7. istaknute su izračunate vrijednosti MAL+ i MAL- za prethodno procijenjene jednadžbe.

Tablica 4.4.6.7.: Procijenjene vrijednosti pomaka potrebnog za prilagodbu srednjoj vrijednosti

Zavisna varijabla:	MAL+	MAL-
DLES95	2,34	1,39
DLDIESEL	2,19	2,54

Izvor: izračun autorice

Prethodno je Wald test pokazao da kod Eurodizela razlika između MAL+ i MAL- nije statistički značajna (iako vrijeme prilagodbe dugoročnoj ravnoteži ide u prilog teze o postojanju pozitivne cjenovne asimetrije), dok je kod Eurosuper 95 navedena razlika (granično) statistički značajna na razini od 10% signifikantnosti. Za Eurodizel navedeno podrazumijeva da ne postoji asimetrija u prilagodbi cijena Eurodizela cijenama nafte, odnosno da se cijene Eurodizela vraćaju svojoj dugoročnoj ravnoteži nakon nešto više od 2 mjeseca neovisno o tome jesu li iznad ili ispod iste (odnosno neovisno o tome prilagođavaju li se smanjenju ili povećanju cijena nafte). Što se tiče Eurosupera 95, analiza je pokazala da je potrebno više vremena (2,34 mjeseca) za prilagodbu dugoročnoj ravnoteži kada su cijene iznad dugoročne ravnoteže nego li kad su cijene ispod ravnotežne (u kom slučaju je potrebno 1,39 mjeseci). Ovakav rezultat upućuje na postojanje cjenovne asimetrije. Ipak, s obzirom da je navedeni rezultat statistički značajan na razini od 10%, a istovremeno je dokazano da ne postoji asimetrija u prilagodbi cijena Eurodizela (koji je sve zastupljeniji u ukupnoj prodaji), može se konstatirati da provedena analiza upućuje na **odbacivanje hipoteze *H6:*** *Cijene naftnih derivata asimetrično reagiraju na promjene cijena nafte*.

4.5. RASPRAVA O REZULTATIMA EMPIRIJSKOG ISTRAŽIVANJA

S ciljem testiranja glavne hipoteze istraživanja: *Cijene nafte statistički značajno utječu na makroekonomske pokazatelje hrvatskog gospodarstva*, provedena je ekonometrijska provjera

šest (6) pomoćnih hipoteza postavljenih u skladu s prijedlogom istraživanja iznesenim u poglavlju 1.3. U ovom poglavlju prezentirani su rezultati provedenog empirijskog istraživanja kao i rasprava o istima. Ujedno je izvršena usporedba rezultata provedenog empirijskog istraživanja u odnosu na ranije prezentirane teorijske i empirijske spoznaje o problematici istraživanja kao i u odnosu na elaboraciju kretanja ključnih makroekonomskih pokazatelja u RH prezentiranih u sklopu poglavlja 3. U ovom su poglavlju istaknuta i ograničenja provedenog istraživanja pri čemu su ograničenja koja se smatraju generalnim ograničenjima istraživanja, a ne samo pojedinih hipoteza, izdvojena u zasebno potpoglavlje.

4.5.1. Kretanje stopa rasta bruto domaćeg proizvoda u odnosu na promjene cijena nafte

Prvom istraživačkom hipotezom testiran je utjecaj cijena nafte na hrvatski BDP (1995:Q1-2015:Q4) pri čemu su kao nezavisne varijable u odnosu na realni BDP odabrane varijable indeksa industrijske proizvodnje, realnog efektivnog deviznog tečaja, te ranije definirani pokazatelji cijena nafte. Analiza impulsnih funkcija odziva (IRF) implicira statistički značajan utjecaj (na razini od 5% signifikantnosti) varijabli MORK+, MORK- i SOPD na realni BDP, pri čemu analiza informacijskih kriterija procijenjenih VAR sustava jednadžbi upućuje na MORK+/MORK- pokazatelj cijena nafte kao najprimjereniji. IRF-ovi pokazuju da je reakcija BDP-a na MORK+ (rast cijena nafte) inicijalno negativna u prva dva tromjesečja, nakon čega postaje pozitivna (a od 4 tromjesečja prestaje biti statistički značajna). Stoga se kumulativni efekt rasta cijena nafte na realni BDP može smatrati neutralnim. S druge strane, MORK- i SOPD, nelinearni pokazatelji koji predstavljaju periode smanjenja cijena nafte, ukazuju na gotovo istovjetnu reakciju realnog BDP-a na pad cijena nafte, i to statistički značajno pozitivnu (unutar prva dva tromjesečja), nakon čega ista prestaje biti statistički značajna. Odabiranje MORK+/MORK- pokazatelja kao optimalnog podrazumijeva asimetričnu reakciju realnog BDP-a na cijene nafte. Pri tome je reakcija u slučaju RH ipak ponešto drugačija od onog što sugerira teorija, tj. da je negativan utjecaj rasta cijena nafte na realni BDP statistički značajan, dok pozitivnog učinka pada cijena nafte na BDP nema, odnosno da nije statistički značajan.

U prilog navedenom sugeriraju i rezultati ispitivanja statističke značajnosti koeficijenata pokazatelja cijena nafte u jednadžbama procijenjenih VAR sustava koji su pokazali da postoji statistički značajna razlika (čime se potvrđuje asimetrija) između reakcije realnog BDP-a na

pozitivne i negativne promjene cijena nafte, a što se ne može reći za preostale varijable u sustavu (odnosno na njihove reakcije na promjene cijena nafte).

Nadalje, važno je istaknuti doprinos varijacije pokazatelja cijena nafte varijacijama realnog BDP-a koji je popriličan. Dekompozicija varijance prognostičke greške realnog BDP-a za model s MORK+/MORK- pokazateljima pokazuje kako se (od odabranih varijabli) čak 30% varijacija realnog BDP-a može pojasniti varijacijama varijabli MORK- (10%) i MORK+ (20%). Također je nužno istaknuti da je analiza pokazala da se dokazani utjecaj cijena nafte na realni BDP ne odvija kanalima realnog efektivnog deviznog tečaja i industrijske proizvodnje. Utjecaj pada cijena nafte (MORK-) na industrijsku je proizvodnju pozitivan, dok rast cijena nafte (MORK+) nema statistički značajan utjecaj na istu. Iako IRF-ovi sugeriraju pozitivan utjecaj industrijske proizvodnje na realni BDP, isti se nije pokazao statistički značajnim (na razini od 5% signifikantnosti). U konačnici, empirijska validacija hipoteze **H1: Promjene cijena nafte statistički značajno negativno utječu na stopu rasta bruto domaćeg proizvoda hrvatskog gospodarstva**, upućuje na zaključak o njenom **prihvaćanju**.

Rezultati empirijskog istraživanja potvrđuju ranije zaključke *Gele (2008)* koji, ispitujući utjecaj svjetskih energetskih šokova na gospodarstvo i osvrćući se samo u pojedinim segmentima na cijene nafte, tvrdi da cijene energije ne predstavljaju ograničavajući faktor rasta hrvatskog gospodarstva, kao i *Jovičića i Kunovca (2017)* koji konstatiraju da je utjecaj cijena nafte na hrvatski realni BDP (2001:Q1-2016:Q2) prilično nejasan iako uglavnom pozitivan (vidjeti Grafikon 3.1.5.). Unatoč nepotpunom pokapanju perioda analize, dekompozicija varijance ovog istraživanja upućuje na usporediv (u odnosu na istraživanje *Kunovac, 2017*) udio cijena nafte u pojašnjavanju dekompozicije varijance varijable realnog BDP-a. Pri tome je važno naglasiti da istraživanje navedenih autora podrazumijeva SVAR metodologiju (VAR s ograničenjima na parametre) kao i korištenje samo jednog pokazatelja nafte (realna cijena Brent u USD) spram ovdje korištenih linearnih i nelinearnih specifikacija cijena nafte. Kao moguće pojašnjenje rezultata ovog istraživanja mogu poslužiti i rezultati *Šušnjara (2014)* koji je istraživanjem cjenovne i dohodovne elastičnosti potražnje za naftnim derivatima u RH (u periodu od siječnja 2006. do prosinca 2010.) zaključio da je dohodovna elastičnost potražnje veća od cjenovne elastičnosti potražnje za naftnim derivatima (motornim benzinom i dizelom), odnosno da je potražnja za naftnim derivatima u RH prvenstveno funkcija dohotka, a tek onda njihovih cijena. Njegovi su zaključci usporedivi s teorijski očekivanim međuodnosom cjenovne i dohodovne elastičnosti potražnje za naftnim derivatima pa tako mogu biti i valjan argument

kojim bi se pojasnio pozitivan odnos realnog BDP-a i cijena nafte. Do 2008. godine cijene nafte su rasle kao i realni BDP, odnosno BDP je rastao unatoč rastu cijena nafte jer je dohodovna elastičnost veća od cjenovne.

Rezultati analize mogu se poistovjetiti i s rezultatima *Korhonen i Ledyaeva (2010)* za Japan gdje autori, razdvajajući pozitivne i negativne naftne šokove (1995:Q3-2006:Q3), zaključuju da je utjecaj negativnog naftnog šoka (kao što su MORK- i SOPD) na japanski BDP statistički značajan i pozitivan, dok je efekt negativnog naftnog šoka (kakav je MORK+), iako statistički značajan, puno skromniji[187]. Procjenjujuću utjecaj simetričnog pokazatelja (realne cijene nafte) na BDP Japana, ukupan je efekt pozitivan, iako ne statistički značajan, jednako kao i kod ove analize za RH. Ipak, vjerojatno je najprimjerenija argumentacija *Cashin et al. (2014)*, kao i *Cunado et al. (2015),* koji, naslanjajući se na istraživanje *Kiliana (2009),* razlikuju tri različite vrste naftnog šoka ovisno o njihovom izvoru, ističući da naftni šok uzrokovan šokom na strani potražnje (uzrokovan snažnom globalnom ekonomskom aktivnošću) rezultira u kratkom roku rastom realnog outputa kod gotovo svih zemalja uvoznica iz njihovog uzorka. Ovdje prikazano i provedeno istraživanje ne podrazumijeva razlučivanje naftnih šokova prethodno istaknutom analogijom, što bi svakako bila ključna preporuka za daljnje istraživanje. Ipak, postojeće konstatacije uvelike služe kao primjerena podloga za zaključak da zaista razlozi koji dovode do promjene cijena nafte na svjetskoj razini ne smiju biti zanemareni. Iako Hrvatska ni na koji način ne može utjecati na svjetske cijene nafte, evidentno je da postoji prilično visok stupanj endogenosti između cijena nafte i globalne ekonomske aktivnosti koja zahvaljujući globalizaciji, otvorenosti gospodarstava pa samim time i podložnosti inozemnim šokovima potencira procikličko kretanje gospodarstava, posebice trgovinskih partnera; s globalne razine na EU razinu, a potom i prema domaćem gospodarstvu. 2000te su (a i ranije) sve do pojave krize obilježene rastom cijena nafte koji je posljedica primarno snažne globalne potražnje, a pozitivne realne stope rasta su u usporedivom periodu karakterizirale i hrvatski BDP. U jeku krize hrvatsko gospodarstvo je „potonulo“, a potom je i usporedno s padom cijena nafte (koncem analiziranog perioda) ponovno započeo uspon.

Ne smije se, naravno, zaboraviti da cijene nafte, iako važan, nisu nikako jedini izvor varijacija realnog BDP-a. Navedeno je u velikoj mjeri posljedica uvođenja pojedinih, nerijetko

[187] *Korhonen i Ledyaeva (2010)* su istražili utjecaj cijena nafte na gospodarstva Rusije, Belgije, Kanade, Francuske, Japana, Njemačke, Nizozemske, Ujedinjenog Kraljevstva, SAD-a, Kine, Italije, Švicarske i Finske.

specifičnih, makroekonomskih politika u domeni monetarne i fiskalne politike, a ništa manje važna nije ni energetska kao ni proizvodna struktura gospodarstva. Nafta je i dalje najzastupljeniji energent pri čemu tekuća goriva u strukturi neposredne potrošnje energije čine 40%. Domaća je proizvodnja nafte sve skromnija, a uvoz sve veći, iako sve više u vidu uvoza naftnih derivata, a sve manje sirove nafte (što je posljedica smanjenja domaćih rafinerijskih kapaciteta). Dok je udio industrije u BDP-u u analiziranom periodu pao sa 20% na 15%, doprinos turizma i trgovine BDP-u premašio je 20%. Upravo je u ovim djelatnostima zastupljenija potrošnja naftnih derivata kroz transport (bilo roba, bilo kroz dolaske turista kojih čak 90% u Hrvatsku dolazi na odmor korištenjem cestovnog prometa; *Šolman, 2010*). Istovremeno, promet je u RH najzastupljeniji potrošač tekućih goriva (2/3 potrošnje goriva), dok industrija troši tek manji dio (*EIHP, Energija u Hrvatskoj 2015, str. 93*). *Katircioglu et al. (2015)* ističu da je snaga utjecaja cijena nafte na makroekonomske pokazatelje (26 OECD zemalja; 1980-2011) pozitivno korelirana sa stupnjem ovisnosti gospodarstva o nafti; ako je nafta glavni pokretač industrije te ako je ista zastupljena u strukturi BDP-a, navedeno rezultira snažnijom reakcijom cjelokupnog gospodarstva. Već je istaknuto da je u strukturi hrvatskog BDP-a udio industrije relativno skroman. Najrazvijenija europska gospodarstva (Njemačka, Francuska, Velika Britanija, Italija, Španjolska), ali i mnoga druga, imaju višu potrošnju energije, kao i tekućih goriva po stanovniku, što znači da je uslijed gospodarskog razvoja i rasta standarda hrvatskih građana realno očekivati i rast potrošnje istih. Posljedično se navedeno može odraziti i na jačanje utjecaja cijena nafte na makroekonomske pokazatelje.

Ne smije se izgubiti iz vida ni utjecaj cijena nafte na vanjskotrgovinske tokove koji direktno utječu na realni BDP jer upravo izvoz i uvoz naftnih derivata te uvoz nafte imaju značajnu poziciju u robnoj razmjeni RH. Ovo je također aspekt utjecaja cijena nafte na hrvatsko gospodarstvo koji bi bilo poželjno detaljnije istražiti. Konačno, unatoč potvrdi postavljene hipoteze o utjecaju cijena nafte na realna gospodarska kretanja, sveobuhvatno kvalitativno i kvantitativno istraživanje navedene tematike nameće važnost identifikacije izvora naftnog šoka kao ključnog u determiniranju makroekonomskih posljedica istog za zemlje uvoznice nafte, što predstavlja ključnu preporuku za daljnje istraživanje.

4.5.2. Odnos cijena nafte i inflacije

Analiziranjem mjesečnih podataka (1995:M01-2015:M12) kretanja varijable CPI u odnosu na kretanje monetarnog agregata M1, kamatne stope, nominalnog efektivnog deviznog tečaja,

industrijske proizvodnje i pokazatelja cijena nafte (LOILN, MORK+, MORK-, SOPI, SOPD, NOPI4) izvršena je empirijska provjera utjecaja cijena nafte na inflaciju. Nominalne su se cijene nafte pokazale kao najprimjereniji pokazatelj promjena cijena nafte, pri čemu rast (točnije šok u visini od 1 S.D.) nominalnih cijena nafte statistički značajno pozitivno utječe na stopu inflacije u prva dva mjeseca nakon šoka nominalnih cijena nafte. Nakon toga utjecaj prestaje biti statistički značajan (vrlo slične reakcije inflacije mogu se uočiti i kod ostalih pokazatelja cijena nafte, no statistički značajne rezultate, pored nominalnih cijena nafte – DLOILN, generirali su samo pokazatelji MORK- i SOPI). Istovremeno, reakcija inflacije na promjene cijena nafte, nakon šoka u varijabli cijena nafte, u potpunosti iščezava koncem prve godine. Temeljem iznesenog donesen je **zaključak o prihvaćanju** hipoteze **H2: Cijene nafte statistički značajno pozitivno utječu na kretanje inflacije**.

Istaknute rezultate nužno je razmotriti u kontekstu prve runde efekata promjena cijena nafte, a to je direktni i najbrži utjecaj cijena nafte na cijene naftnih derivata, koji se gotovo trenutačno prelijeva na cijene u zemlji. U prvoj rundi efekata promjene cijena nafte se najbrže odražavaju na inflaciju kroz utjecaj na cijene naftnih derivata koje krajnji potrošači kupuju neposredno. Pri tome snaga navedenog utjecaja ovisi o zastupljenosti izdataka za naftne derivate u ukupnim troškovima (*Žikov et al., 2019*). Što je veći udio izdataka za naftne derivate, snažniji je i neposredan utjecaj cijena nafte na inflaciju. Tako i *Choi et al. (2018)*, istražujući utjecaj fluktuacija svjetskih cijena nafte na inflaciju za period od 2000. do 2015. godine, zaključuju da su varijacije u rezultatima među zemljama obuhvaćenim uzorkom ponajviše posljedica udjela troškova za transport u potrošačkoj košarici koji u najvećoj mjeri determinira jačinu direktnog utjecaja cijena nafte na rast inflacije. O udjelu troškova za transport u potrošačkoj košarici će detaljnije biti riječi u nastavku prilikom analize (promjena) strukture potrošnje kod elaboracije rezultata empirijske provjere hipoteze H4.

Cashin et al. (2014), na tragu istovjetnih zaključaka *Kiliana (2009),* konstatiraju da šokovi na strani ponude nafte rezultiraju rastom proizvodnih troškova što djeluje proinflatorno, dok šokovi na strani potražnje za naftom rezultiraju tek privremenim proinflatornim utjecajem na inflaciju. U skladu s navedenim, mogu se dovesti i rezultati ovog istraživanja koji impliciraju kratkoročan utjecaj cijena nafte na inflaciju (2 mjeseca), odnosno upućuju na promatranje naftnog šoka kao šoka na strani potražnje. *De Gregorio et al. (2007)* također smatraju da bi inflacija trebala različito reagirati na naftne šokove, ovisno o tome smatraju li se isti kratkotrajnima ili dugotrajnima, pa tako ističu da je prelijevanje cijena nafte u inflaciju bilo

slabije sredinom 2000ih jer se smatralo da je tadašnji rast cijena nafte samo privremen, a ne dugotrajan kao što se u konačnici ispostavilo (kao posljedica snažne globalne potražnje za naftom). U prilog njihovoj tezi govore i podaci (prikazani Grafikonom 3.2.2.) o godišnjim stopama inflacije i doprinosima pojedinih komponenata inflaciji potrošačkih cijena u Hrvatskoj (2006:M01-2015:M12) koji sugeriraju relativno skroman doprinos cijena energije (od čega prvenstveno nafte) inflaciji polovinom 2000ih, što se drastično mijenja od drugog dijela 2008. godine. *Malešević Perović (2009),* kao i *Krtalić i Benazić (2010),* također tvrde da su cijene nafte utjecale na rast inflacije nakon 2001. godine kada su cijene naftnih derivata počele u većoj mjeri odražavati kretanje svjetskih cijena nafte. Također, značajan doprinos cijena energije inflaciji zabilježen je kroz cijelu 2012. i početak 2013. godine, a vrijedno je naglasiti i doprinos drastičnog pada cijena nafte deflaciji u drugom dijelu 2015. godine.

U prilog navedenom mogu se istaći i rezultati *Krznar i Kunovac (2010)* koji su, istražujući učinke prelijevanja vanjskih šokova na inflaciju i BDP u Hrvatskoj (2000:Q2-2010:Q1), zaključili da su upravo inozemni činitelji glavne determinante domaće inflacije i gospodarske aktivnosti. Naftni se šokovi, zbog globalnog karaktera formiranja njihovih cijena, smatraju inozemnim šokom. Uslijed rasta cijena nafte dolazi do uvozne inflacije jer se glavnina nafte namiruje iz uvoza (kako sirove nafte koja se prerađuje u domaćim rafinerijama, tako i njenih derivata). *Globan et al. (2014)* također, istražujući doprinos domaće i inozemne komponente (šokova) inflaciji u novim članicama EU-a koje nisu članice euro zone[188] (2001:M05-2013:M06), ukazuju na činjenicu da je jedino u Hrvatskoj u kratkom i srednjem roku[189] izraženija inozemna komponenta inflacije u doprinosu ukupnoj inflaciji, pri čemu se kod svih zemalja iz uzorka korelacija inozemne komponente u odnosu na inflaciju smanjila u vrijeme krize (2009-2011)[190]. Istražujući doprinos domaće i inozemne potražnje kao i globalnih šokova (uključujući i naftne) kretanjima domaće inflacije i BDP-a (2001:Q1 – 2016:Q2) u Hrvatskoj, *Jovičić i Kunovac (2017)* konstatiraju da inozemni (svjetski i europski) šokovi imaju visok utjecaj na varijabilnost inflacije (od oko 50%), odnosno na varijabilnost BDP-a (od oko 40%). Na istom tragu i u ovom istraživanju provedena analiza dekompozicije varijance implicira da su, kada se izuzme udio varijance vlastite prognostičke pogreške, cijene nafte primarni izvor

[188] Bugarska, Češka, Hrvatska, Latvija, Litva, Mađarska, Poljska i Rumunjska
[189] U srednjem roku i kod preostalih analiziranih zemalja dolazi do povećanja udjela inozemne komponente u doprinosu inflaciji (u odnosu na domaću komponentu).
[190] Autori smatraju da je navedeno posljedica strelovitog pada uvoza, koji je uslijedio uslijed krize, što je ograničilo inozemni utjecaj na domaću inflaciju u promatranom periodu.

varijabilnosti varijable DLCPI (među preostalim odabranim varijablama modela). *Jovičić i Kunovac (2017)* nadalje smatraju da je pad cijena nafte značajno doprinio padu inflacije koncem analiziranog perioda pri čemu ističu da je ovaj odnos ovisan i o samom inicijalnom uzroku naftnog šoka (da li je isti posljedica poremećaja na strani ponude ili potražnje za naftom). Procjenjujući utjecaj šokova na inflaciju, i *Jovičić i Kunovac (2017)* zaključuju da je koeficijent kojim procjenjuju utjecaj cijena nafte na inflaciju pozitivan.

Istražujući utjecaj cijena nafte na inflaciju u 11 srednjoistočnih EU gospodarstava[191], uključujući i Hrvatsku (1996:M01-2018:M06), *Živkov et al. (2019)* zaključuju da je utjecaj cijena nafte na inflaciju, iako pozitivan, relativno skroman. To se može poistovjetiti i sa zaključcima ovog istraživanja koji navode statistički značajan, iako ne pretjerano snažan, utjecaj cijena nafte na inflaciju. Relativno skromne reakcije inflacije se mogu pojasniti i iznimno stabilnom razinom inflacije u RH, pri čemu prosječna visina inflacije u analiziranom periodu nadilazi vrijednosti inflacije kod članica euro zone, ali je istovremeno niža od iste kod EU10 članica. Tako i *Zoli (2009)* [192] zaključuje da je reakcija inflacije na rast cijena nafte (nakon 6 mjeseci) najskromnija upravo u Hrvatskoj u odnosu na prosječnu reakciju europskih gospodarstava u razvoju[193]. S druge pak strane, *Živkov et al. (2019)* smatraju da je utjecaj cijena nafte na inflaciju u većini zemalja najizraženiji u dugom roku što implicira izraženiju drugu rundu efekata rasta cijena nafte.

Nadalje, nužno je naznačiti i kontinuirano praćenje utjecaja kretanja cijena nafte na inflaciju u RH od strane monetarnih vlasti, a što je vidljivo kroz pažnju koja se posvećuje istom unutar periodičkih publikacija HNB-a. Tako se i u recentnoj publikaciji HNB-a (*HNB, Makroekonomska kretanja i prognoze, 2018, str. 16*) navodi: „*Energija je i nadalje komponenta koja daje najveći doprinos inflaciji (1,0 postotni bod), od čega se pretežni dio odnosi na naftne derivate.*“, pri čemu se, primjerice, u 2018. više od 50% ukupnog rasta inflacije pripisuje upravo rastu cijena nafte. U istoj se publikaciji nadalje navodi: „*Cijene goriva imaju važan utjecaj na kretanje ukupne inflacije potrošačkih cijena u Hrvatskoj zbog važnosti goriva u potrošnji kućanstava i izravnog utjecaja svjetskih cijena sirove nafte.“ (HNB, Makroekonomska kretanja i prognoze, 2018, str. 18).* Istovremeno je nužno naznačiti, na tragu zaključaka *Bodenstein,*

[191] Analizirana gospodarstva uključuju: Bugarsku, Hrvatsku, Češku, Estoniju, Mađarsku, Latviju, Litvu, Poljsku, Rumunjsku, Slovačku i Sloveniju.
[192] U periodu od 1990ih do 2008 (uzorak se blago razlikuje među zemljama).
[193] Bugarska, Hrvatska, Češka, Estonija, Mađarska, Litva, Latvija, Srbija, Slovačka, Slovenija, Turska i Ukrajina.

Guerrieri i Kiliana (2012) da monetarna politika kontinuirano prilagođava svoje reakcije na naftne šokove, čime se podiže i njen kredibilitet.

Detektirani pozitivan utjecaj cijena nafte na inflaciju u RH može se dovesti u vezu s istovjetnim zaključcima niza istraživanja, kako u razvijenim (*Pierce i Enzler, 1974*; *Bernanke, Gertler i Watson, 1997*; *Hamilton, 1983, 1988, 1996, 2000; Tatom, 1988; Mork, 1989; Mork et al., 1994; Kahn i Hampton, 1990; Hooker, 1996, 1999a,b; Huntington, 1998, Cunado i Perez de Gracia, 2003; LeBlanc i Chinn, 200; Chen, 2009; Álvarez et al., 2011)* tako i u zemljama u razvoju *(Cunado i Perez de Gracia, 2005; ESB, 2013; Gelos i Ustyugova, 2017; Živkov et al., 2019)*.

Istraživanja utjecaja cijena nafte na inflaciju nerijetko su posljedica istraživanja reakcije monetarnih vlasti na naftne šokove. Od svih makroekonomskih pokazatelja, upravo bi inflacija trebala najbrže reagirati na promjene cijena nafte. Navedeno se i kod ovog istraživanja pokazalo točnim, iako utjecaj cijena nafte na inflaciju ovisi i o načinu na koji reagira monetarna politika na naftni šok. Imajući u vidu način vođenja monetarne politike od strane HNB-a, postojeća istraživanja kanala monetarne transmisije u RH kao i netom izneseno, pored same inflacije u model istraživanja uključuju i varijable: nominalnog efektivnog deviznog tečaja, kamatne stope i novčane mase.

Kada je riječ o nominalnom efektivnom deviznom tečaju, kod svih je procijenjenih VAR sustava evidentiran statistički značajan pozitivan utjecaj nominalnog efektivnog deviznog tečaja na inflaciju (temeljem IRF-ova), 3 do 5 mjeseci nakon šoka u varijabli kojom je predstavljena promjena cijena nafte. Također, može se istaknuti kako su svi modeli detektirali statistički značajnu Granger uzročnost u smjeru od nominalnog efektivnog deviznog tečaja ka kamatnoj stopi, kao i od nominalnog efektivnog deviznog tečaja ka novčanoj masi (M1). Konzistentnost ovih rezultata, kroz VAR sustave s različitim pokazateljima cijena nafte, ukazuje na dobru definiranost modela, ali i usporedivost s rezultatima postojećih empirijskih istraživanja u RH. Stabilan tečaj kune prema euru predstavlja tzv. nominalno sidro monetarne politike kojim HNB stabilizira inflacijska očekivanja, a naposljetku i inflaciju (*HNB, 2018b*), što potvrđuju i netom izneseni rezultati istraživanja u prilog deviznog tečaja kao primarnog alata vođenja monetarne politike, odnosno kanala utjecaja na inflaciju u RH. Izbor monetarnog okvira ovisi o važnim obilježjima i osobitostima gospodarstva, a za hrvatsko gospodarstvo

najvažniji je visok stupanj euroizacije. Istraživanja *Luca i Petrova (2008) i Levy Yeyati (2006)* ističu upravo Hrvatsko[194] gospodarstvo kao ono s najvišim stupnjem euroizacije u Europi.

Unatoč navedenim vezama, analiza nije ukazala na statistički značajan utjecaj cijena nafte na nominalni efektivni devizni tečaj. Veza cijena nafte i tečaja USD koja je nerijetko dokazana kao važna, ovdje provedena analiza potencijalno nije prikazala značajnom zbog korištenja pokazatelja nominalnog efektivnog deviznog tečaja, što je „šira" mjera kretanja deviznih tečajeva koja po svoj definiciji tek u manjoj mjeri obuhvaća bilateralni tečaj HRK/USD (valute glavnih trgovinskih partnera i njihovi ponderi određeni su na osnovi strukture uvoza i izvoza robe prerađivačke industrije).

Nadalje, analiza nije detektirala statistički značajan utjecaj cijena nafte na kamatnu stopu, monetarni alat koji FED i ESB primarno koriste s ciljem monetarne transmisije. Naime, korištena metodologija jednaku važnost pridaje utjecaju cijena nafte na preostale varijable u cijelom promatranom periodu (1995-2015). Ako se ovome pridodaju zaključci ranijih istraživanja o neučinkovitosti kanala kamatne stope (*cf. Vizek, 2006; Benazić, 2009*) kao i činjenica da su operacije na otvorenom tržištu s ciljem povećanja važnosti kanala kamatne stope kao i stabilizacije kamatnih stopa na tržištu novca u RH uvedene tek 2005. godine što je rezultiralo aktivacijom transmisijskog mehanizma kamatne stope tek u drugom dijelu analiziranog perioda (*Vizek i Broz, 2007; Borozan, 2011; Borozan i Sonora, 2014*), ovaj je rezultat donekle i očekivan.

Jednako tako, analiza nije pokazala statistički značajan utjecaj cijena nafte na novčanu masu, odnosno monetarni agregat M1, iako se pokazalo da u prva dva mjeseca inflacija, odnosno CPI, što je teorijski utemeljeno i očekivano, statistički značajno pozitivno reagira na rast novčane mase. Istovremeno, monetarni agregat M1 trenutno negativno (i statistički značajno) reagira na šok u varijabli NEER. Ipak, reakcija je ograničena tek na dva mjeseca. Upravo je politika sidra nominalnog deviznog tečaja uzrok tijesne veze novčane mase i deviznih pričuva (Vidjeti Grafikon 3.2.2.2.). Ublažavanje deprecijacijskih pritiska središnja banka uglavnom vrši prodajom deviza čime smanjuje količinu domaćeg novca u opticaju.

[194] pored Armenije i Gruzije

Ovome valja dodati i, ovim istraživanjem uvažene, navode o mogućem asimetričnom utjecaju cijena nafte na inflaciju koji se klasičnim simetričnim modelima zanemaruju u potpunosti (*Mork, 1989; Hamilton, 2009, 2011; Herrera, 2001; Valcarcel i Wohar, 2013; Salisu et al., 2017*). Ipak, analiza je pokazala da je utjecaj cijena nafte na inflaciju pozitivan, odnosno da ne postoji asimetrija u prilagodbi inflacije pozitivnim i negativnim promjenama cijena nafte.

Temeljem iznesenog, a na tragu postojećih empirijskih istraživanja, kako u razvijenim tako i u zemljama u razvoju, cijene nafte bi se svakako trebale uzeti u obzir prilikom modeliranja inflacije općenito, pa tako i Hrvatskoj. Pri tome bi monetarne vlasti trebale uzeti u obzir ne samo promjene cijena nafte već i uzrok istih. Kao ograničenje provedenog istraživanja, te ujedno preporuka za daljnje istraživanje, s ciljem boljeg razumijevanja načina na koji cijene nafte utječu na inflaciju uputno je razmotriti inflaciju na dezagregiranoj razini kako bi se u potpunosti izdvojile cijene dobara i usluga podložne administrativnom određivanju jer iste ne odražavaju (u potpunosti) efikasno djelovanje tržišta.

4.5.3. Reakcija nezaposlenosti na promjene cijena nafte

Treća hipoteza koja implicira da **rast cijena nafte statistički značajno povećava nezaposlenost, dok pad cijena nafte nema statistički značajan utjecaj na nezaposlenost**, provjerena je ispitivanjem utjecaja realnih plaća, realne kamatne stope i pokazatelja cijena nafte (LOIL, MORK+, MORK-, SOPI, SOPD, NOPI4) na stopu nezaposlenosti (2000:M01-2015:M12), pri čemu je donesena odluka o **neprihvaćanju** iste.

Minimizacija informacijskih kriterija kao i korigirani koeficijent determinacije procijenjenih jednadžbi stope nezaposlenosti sugerirali su SOPI/SOPD pokazatelj kao najprimjereniji. Kod modela sa SOPI/SOPD pokazateljima cijene nafte, funkcija impulsnog odziva pokazuje pozitivan utjecaj varijable SOPI na stopu nezaposlenosti u 4 mjesecu nakon inicijalnog šoka. Ovaj se rezultat može dovesti u vezu s istraživanjima *Lee, Ni i Ratti (1995)* i *Ferderera (1996).* Rezultati *Ferdererova (1996)* istraživanja impliciraju da agregatna nezaposlenost raste kada relativni cjenovni šokovi postaju volatilniji, odnosno da volatilnost cijena nafte osnažuje poremećaje u sektorskim prilagodbama na tržištu rada, vodeći višim stopama nezaposlenosti. Jednako tako i *Lee, Ni i Ratti (1995)* ističu kako neočekivanost promjene cijena nafte ima puno jači utjecaj na razinu zaposlenosti od same promjene cijena nafte. Ipak, donja granica procijenjenog intervala se smjestila blago ispod horizontalne linije grafikona, a ni analiza

Granger uzročnosti nije dala naslutiti statistički značajan utjecaj varijable SOPI na stopu nezaposlenosti. Stoga je uputno i navedeni rezultat uzeti s rezervom.

Nadalje, iako pojedini pokazatelji cijena nafte tek marginalno statistički značajno utječu na stopu nezaposlenosti, nema nikakvih naznaka asimetričnoj reakciji stope nezaposlenosti na cijene nafte. Tako i ranije spomenuti pokazatelji SOPI/SOPD pokazuju pozitivnu vezu cijena nafte i stope nezaposlenosti neovisno o smjeru promjene cijena nafte. Ipak, kad se uzmu u obzir granice procijenjenih intervala pouzdanosti, analiza nije dala naslutiti statistički značajan utjecaj cijena nafte na stopu nezaposlenosti, kao ni asimetriju u prirodi tog utjecaja.

Ovakav se rezultat može u velikoj mjeri poistovjetiti sa zaključcima *Cuestas i Gil-Alana (2018)* koji ukazuju na nepostojanje utjecaja cijena nafte na stopu nezaposlenosti u zemljama srednje istočne Europe (iako RH nije uključena u njihov uzorak). Autori ne detektiraju (ni kratkoročan) ni dugoročan odnos stope nezaposlenosti i cijena nafte, što pak ne vrijedi kada u analizi uzmu u obzir prirodnu stopu nezaposlenosti. Analizirajući utjecaj cijena nafte na prirodnu stopu nezaposlenosti autori detektiraju pozitivnu statistički značajnu vezu za Poljsku, Mađarsku, Litvu i Latviju, dok kod Estonije, Češke, Slovenije i Slovačke čak ni u ovom slučaju ne nalaze pozitivnu vezu. Razlog koji navode kao pojašnjenje potonjih rezultata u velikoj se mjeri može poistovjetiti i sa situacijom u Hrvatskoj. Naime, autori ističu sindikalnu gustoću radne snage kao i nisku fleksibilnost tržišta rada kao temeljne razloge nepovezanosti cijena nafte i stopa nezaposlenosti.

Kako je već i ranije istaknuto (u sklopu poglavlja 3.3.) upravo je niska fleksibilnost jedna od temeljnih karakteristika hrvatskog tržišta rada. U Hrvatskoj je prisutan nedostatak fleksibilnosti na tržištu rada, čime se uz klasičnu nezaposlenost, koja se ogleda u nedostatku radnih mjesta, povećava i strukturna nezaposlenost, uočljiva u neskladu strukture ponude i potražnje, jer kvalifikacije nezaposlenih ne odgovaraju zahtjevima slobodnih radnih mjesta (*Petrović Štefanac, 2012*). Nadalje, *Obadić (2016)* ističe da je, unatoč njihovoj disperziranosti, razina sindikalne gustoće u Hrvatskoj oko 35% kao i da se sve veće značenje pridaje socijalnom partnerstvu između poslodavaca, sindikata i vlade. Zahvaljujući puno većoj sindikalnoj gustoći u javnom sektoru, fluktuacije zaposlenosti su puno izraženije u privatnom sektoru koji je u periodu prije krize i bio primarni generator rasta zaposlenosti, ali je, jednako tako, u vremenu krize, u puno većoj mjeri podnio njen teret. U javnom sektoru i plaće su u prosjeku više nego u privatnom (*Mrnjavac, 2011; Obadić i Tica, 2016*). Slaba reakcija tržišta rada na promjene

cijena nafte može se dovesti u vezu i s reakcijama javnog sektora koji je u vremenima krize (od početka 2009. godine), za razliku od privatnog sektora, a potpuno nerealno s obzirom na realni pad BDP-a, i dalje bilježio pozitivne stope rasta broja zaposlenih (vidjeti Grafikon 3.3.5). Rezultate analize nužno je stoga promatrati u kontekstu, ranije iznesene, analize hrvatskog tržišta rada (vidjeti Poglavlje 3.3.) koje je okarakterizirano iznadprosječnim stopama nezaposlenosti u cijelom promatranom periodu kao i radom u neslužbenom gospodarstvu (zbog neučinkovitog kažnjavanja istog), ispodprosječnim stopama zaposlenosti i aktivnosti stanovništva, niskom produktivnošću rada (koja je donekle povezana i s niskim troškom rada) te priličnom rigidnošću nadnica.

Evidentno je da hrvatsko tržište rada odlikuju duboko ukorijenjeni strukturni problemi koji potencijalno maskiraju njegovu stvarnu reakciju na promjene cijena nafte. Kao uzrok visoke nezaposlenosti može se dodati i visok porezni klin, niska produktivnost radne snage (oko 80% EU28 prosjeka) kao i relativno visok indeks zakonske zaštite zaposlenja (*Obadić, 2016*). Tako i rezultati istraživanja *Kunovac i Pufnik (2015*), za period krize od 2010. do 2013. sugeriraju izrazito visok udio poduzeća koji kao prepreke pri zapošljavanju novih radnika smatra visoke poreze na plaće kao i visoke troškove ostalih proizvodnih faktora (osim rada), rizik promjene Zakona o radu, nedostupnost radne snage s potrebnim vještinama i visoke troškove otpuštanja.

Kao zaključak prethodno iznesenog, hipoteza H3 se odbacuje jer nije dokazan utjecaj cijena nafte na kretanje nezaposlenosti, kao ni postojanje asimetrije u odgovoru stope nezaposlenosti na promjene cijena nafte, o kojoj nema ni naznaka. Na tragu navedenog, može se zaključiti da promjene cijena nafte (bar one značajnije) ne rezultiraju sektorskim realokacijama radne snage što je posljedica nefleksibilnosti tržišta rada, visoke sindikalne gustoće kao i visokom razinom zakonske zaštite zaposlenja. Pokazatelji poslovne klime i konkurentnosti koje objavljuju međunarodne institucije kvalificiraju Hrvatsku kao zemlju s rigidnim tržištem rada i visokom razinom zakonske zaštite zaposlenja (*Kunovac, 2014*). Također, slaba reakcija tržišta rada na promjene cijena nafte potencijalno je i posljedica niskog udjela industrije u ukupnom BDP-u od maksimalnih 15% u analiziranom periodu (2008.) do 12% koncem analiziranog perioda (*DZS, 2018b*).

Rotemberg i Woodford (1996) smatraju da je neosjetljivost stope nezaposlenosti na promjene cijena nafte potencijalno odraz i pada energetske intenzivnosti i rasta energetske učinkovitosti, trenda koji je posebice izražen u razvijenim ekonomijama proteklih desetljeća. Navedeni

pokazatelji u RH pokazuju istovjetan trend, te je zamjetan pad energetske intenzivnosti za više od 15% (primarno kao rezultat smanjenja jedinične potrošnje energije, u industriji preko 40%) uz istovremeni rast energetske učinkovitosti općenito, ali i rasta energetske učinkovitosti u sektorima prometa (za 15%) i industrije (više od 30%) (*EIHP, Energija u Hrvatskoj, 2015, str. 218*). *Katircioglu et al. (2015),* na istom tragu zaključuju da je utjecaj cijena nafte na nezaposlenost (u 26 zemalja OECD-a, 1980-2011) u najbolju ruku marginalan, pri čemu navedeno pojašnjavaju uspješnim poticanjem energetske efikasnosti unutar analiziranih gospodarstava.

Naslanjajući se na zaključke *Monfort et al. (2019)* koji su istražili utjecaj cijena nafte na nezaposlenost u Španjolskoj (2001:Q1-2014:Q4) te zaključili da je isti različit prije i nakon krize 2008. godine (do 2008:Q1 nezaposlenost se smanjivala, a nakon 2008:Q1 ista je rasla kao odgovor na naftni šok), kao i *Andreopoulosa (2009)* koji implicira da cijene nafte pomažu u predviđanju stopa nezaposlenosti (u SAD-u) u vrijeme recesije, svakako bi bilo poželjno istražiti postoji li razlika u navedenim efektima i u slučaju RH, na što upućuju podaci predočeni Grafikonom 3.3.3.

U konačnici, valja uzeti u obzir i frekvenciju podataka (mjesečnu) kako bi se mogao procijeniti dugoročan utjecaj cijena nafte na nezaposlenost. Razlog zašto je odabrana mjesečna frekvencija krije se u relativnoj kratkoći odabranih vremenskih nizova zbog čega ekonometrijski kriteriji upućuju na korištenje vremenskih nizova više frekvencije čime se raspolaže i većim brojem podataka za isti vremenski period. Kako navode istraživanja *Lardic i Mignon (2006), Carruth et al. (1998), Doğrul i Soytas (2010), Chang et al. (2011) i Ran i Voon (2012)* pozitivan utjecaj rasta cijena nafte na rast nezaposlenosti vidljiv je tek u dugom roku, odnosno događa se s vremenskim odmakom pri čemu *Chang et al. (2011)* također naglašavaju da unutar grupacije analiziranih gospodarstava navedeno vrijedi za razvijena gospodarstva dok kod većine zemalja u razvoju navedenog odnosa ni nema (kako sugeriraju i rezultati istraživanja za Hrvatsku).

4.5.4. Uloga cijena nafte u kretanju osobne potrošnje

Hipotezom H4 ispitan je utjecaj cijena nafte na osobnu potrošnju u RH (2000:Q1-2015:Q4) pri čemu su u model uključeni pokazatelji cijena nafte te varijable osobne potrošnje, stope nezaposlenosti i realnog raspoloživog dohotka. Ekonometrijska analiza je ukazala na nepostojanje statistički značajnog utjecaja cijena nafte na kretanje osobne potrošnje. Jedino je

kod VAR sustava s NOPI4 pokazateljem cijena nafte detektirana Granger uzročnost u smjeru od cijena nafte ka osobnoj potrošnji (koja bi mogla sugerirati značajan međusobni utjecaj u navedenom smjeru) i to uz razinu signifikantnosti od 10%. To je kasnije potvrđeno i provedbom Wald testa i IRF. IRF sugerira negativnu reakciju osobne potrošnje na NOPI4 koja je najizraženija 4 tromjesečja nakon šoka u varijabli NOPI4, dok ista u potpunosti iščezava koncem sedmog tromjesečja. Pri tome je reakcija na šok od jedne S.D. u varijabli NOPI4 pad realne potrošnje od 0,2% nakon 4 tromjesečja, dok dekompozicija varijance implicira da se 15% varijance prognostičke greške varijable osobne potrošnje može pojasniti kretanjem varijable NOPI4. Ovdje je važno naglasiti da su ekonometrijske postavke VAR metodologije, kao i ograničenja u vidu dostupnosti dostatno dugog vremenskog niza, rezultirali odabirom broja vremenskih odmaka (3 tromjesečja za NOPI4 i 1 tromjesečje za modele s preostalim pokazateljima cijena nafte) koji nije dostatan kako bi se obuhvatio dovoljno dug period unutar kojeg bi se mogle očekivati značajnije promjene u osobnoj potrošnji.

Dok je korigirani koeficijent determinacije sugerirao NOPI4, AIC je sugerirao SOPI/SOPD, a SBS DLOIL kao najprimjereniji pokazatelj kretanja cijena nafte. Kako se u dosadašnjem tijeku istraživanja inzistiralo na potvrđivanju istovjetnih rezultata svim navedenim testovima (ili barem dva od tri) što ovdje nije bio slučaj, valja s oprezom tumačiti rezultate NOPI4 pokazatelja (jer su ionako granično statistički značajni) te konstatirati da se, temeljem provedene empirijske provjere, hipoteza **H4: Promjene cijena nafte statistički značajno negativno utječu na kretanje osobne potrošnje, odbacuje.**

Postojanje troška praćenja promjena cijena nafte, kao i prilagodbe uzorka potrošnje, potencijalno čini kućanstva neosjetljivima na manje promjene cijena nafte (*Goldberg, 1998; Kilian, 2008a*). Slijedom navedenog, kako pretpostavlja i korišteni pokazatelj NOPI4, potrošači reagiraju samo na promjene cijena, pogotovo pozitivne, koje do tada (povijesno) nisu zabilježene. *Mehra i Petersen (2005)*, kao i *Kocaaslan (2019)*, također sugeriraju značajniji utjecaj naftnog šoka na pad potrošnje kada je isti neočekivan, odnosno kada uslijedi nakon dužeg perioda relativno stabilnih cijena.

Utjecaj naftnih šokova na potrošnju tek je nedavno došao u fokus nekolicine relevantnih istraživanja (*Mehra i Petersen, 2005; Odusami, 2010; Wang, 2013*) u kojima je osobna potrošnja modelirana korištenjem *Friedmanove (1956)* hipoteze permanentnog dohotka. Ograničenje ovog istraživanja u vidu nepostojanja podataka o bogatstvu, pa i realnom dohotku

(koji je ovdje aproksimiran umnoškom realne mase plaća i broja zaposlenih) u RH u stvarnosti onemogućava usporedivu empirijsku provjeru hipoteze permanentnog dohotka. Ipak, ovdje je detektiran tek granični negativan utjecaj rasta cijena nafte na osobnu potrošnju i to kada se koristi pokazatelj NOPI4, a što i jest u skladu s teorijskim postavkama testirane hipoteze. Nužno je naznačiti i relativno kratkoću korištenih vremenskih nizova zbog koje se, kako navode i *Zhank i Broadstock (2014)* analizirajući čak i dulji vremenski period (1988:Q1-2012:Q4), ne smije definitivno zaključiti da ne postoji utjecaj cijena nafte na osobnu potrošnju već da je istog teško dokazati unutar uskog vremenskog perioda koji je između ostalog obilježen i izraženim konjunkturnim kretanjima realnog gospodarstva.

Nadalje je važno istaknuti da su ekonometrijske postavke (ograničenja) modela rezultirale odabirom tek 1 tromjesečja kao optimalnog broja vremenskih odmaka kod procijenjenih VAR sustava s preostalim pokazateljima cijena nafte, što je premalo kako bi se obuhvatio period značajnijih promjena potrošnje. Tako i *Wang (2013)* ističe da se proces prilagodbe osobne potrošnje cijenama nafte odvija tromo i postupno kao posljedica prvenstveno niske cjenovne elastičnosti potražnje za naftnim derivatima kao i njihovim komplementima. Također, *Mehra i Petersen (2005)* konstatiraju da rast cijena nafte, koji je posljedica snažne globalne potražnje, ne mora rezultirati zabrinutošću glede budućih cijena nafte pa samim time ni promjenama u potražnji, posebno za trajnim potrošnim dobrima. Navedeno bi se moglo konstatirati i u RH. Naime, u pred-kriznom periodu (od 2005. do 2008.) broj prodanih novih automobila porastao je za više od 25% (vidjeti Grafikon 3.6.3.), dok je istovremeno realna cijena nafte porasla preko 45% uz istovremeni rast realnog BDP-a od 30%. Dakle, i realni je BDP, pa i broj novih registriranih vozila rastao unatoč rastu cijena nafte. Navedeno govori u prilog netom iznesenoj tezi *Mehra i Petersen (2005).*

S druge strane, struktura potrošnje po kućanstvu (ranije prikazana Tablicom 3.4.3.) pokazuje da su u periodu obilježenim krizom, od 2006. do 2014. godine, ukupni izdaci za prijevoz porasli za 18,2% pri čemu su izdaci za kupnju vozila smanjeni za čak 37% uz istovremeni rast troškova održavanja vozila za 60%. Rast troškova održavanja vozila posljedica je iznimnog rasta izdataka za rezervne dijelove (116,3%) i goriva i maziva (56,5%). Izdaci za putnički promet i usluge također su porasli za 81%. Istovremeno je cijena barela nafte porasla 50% (prosječna cijena dizela i bezolovnog motornog benzina za 15,5% odnosno 24,7%) a prosječna mjesečna neto plaća svega 7%. *Edelstein i Kilian (2009)* kao i *Elder i Serletis (2010)* zaključuju kako potrošnja trajnih dobara statistički značajno negativno reagira na naftni šok, posebno kad je

riječ o automobilima. Štoviše, *De Michelis, Ferreira i Iacoviello (2019)* impliciraju da broj registriranih novih automobila ima prednost spram pokazatelja agregatne osobne potrošnje. Tako i podaci u RH pokazuju da je nakon naftnog šoka 2008. godine broj registriranih novih automobila pao za više od 50% unutar perioda od samo dvije godine (vidjeti Grafikon 3.6.3.).Na istom tragu i *Herrera et al. (2019),* analizirajući dotadašnja istraživanja u SAD-u, konstatiraju da upravo potražnja za automobilima pojašnjava najveći dio kontrakcije osobne potrošnje uslijed naftnog šoka. U skladu s navedenim je i pokazatelj prosječne starosti automobila na hrvatskim cestama koji je u periodu od 2007. do 2015. godine porastao sa 9,83 na 12,52, potvrđujući trend odgađanja kupnje automobila. Istovremeno je 2009. po prvi puta zabilježen pad ukupnog broja registriranih osobnih automobila koji je tako 2015. iznosio 1 516 698 u odnosu na 1 537 981 automobila 2008. godine (*EIHP, Energija u Hrvatskoj 2015, str. 222*). Na istom tragu mogu se navesti i promjene u strukturi potražnje za automobilima kroz sve veći udio manjih dizelskih motora kojih su 1995. činili 17,5%, a 2015. 43,29% ukupnog broja registriranih automobila. Navedene strukturne promjene utemeljene su isključivo na tržišnim principima povoljnije cijene dizelskih goriva (u odnosu na benzinska), bez prisustva institucionalnih poticajnih mjera (*EIHP, Energija u Hrvatskoj 2015, str. 224).* Sve navedeno govori u prilog izraženim trendovima prilagodbe strukture potrošnje spram njene sgregatne vrijednosti.

Sama potrošnja po kućanstvu, koja i nije značajno oscilirala (u promatranom je periodu zabilježila nominalni rast od 8,7%), svojom strukturom sugerira značajne prilagodbe ponašanja kućanstava i to posebno u segmentu u kojem cijene naftnih derivata imaju direktan utjecaj na potrošnju; njihova neposredna kupnja, kupnja njihovih komplemenata – prvenstveno automobila, kao i ukupni izdatci za prijevoz. Temeljem navedenog može se konstatirati da se utjecaj cijena nafte na osobnu potrošnju, pa tako i potrošnju kućanstava, prvenstveno očituje kroz prilagodbu strukture potrošnje. Stoga je direktan međusobni utjecaj jako teško detektirati na agregatnoj razini. Zbog navedenog, potrebno je detaljnije sagledati promjene u strukturi potrošnje, odnosno reakciju pojedinih segmenata potrošnje kućanstva, konkretnije provesti analizu utjecaja cijena nafte (naftnih šokova) na osobnu potrošnju po pojedinim segmentima (kategorijama) iste. Da bi se mogle provesti kvalitetne analize promjene strukture potrošnje u odnosu na promjene cijena nafte, nužno je raspolagati s (dovoljno dugim) dezagregiranim vremenskim nizovima. Nažalost ankete o potrošnji kućanstava koje provodi DZS provodile su se na godišnjoj razini do 2011. godine nakon čega se periodika promijenila u višegodišnju (tako, primjerice, nikakvi podaci za 2012. i 2013. nisu raspoloživi, a podaci generirani od 2014.

godine nadalje nisu u potpunosti usporedivi s prijašnjima zbog primjene metode utežavanja podataka od 2014. nadalje; *DZS, Statistička izvješća 1557/2015*). Također je potrebno istaknuti činjenicu da za RH još uvijek ne postoje podaci o realnom dohotku kao ni bogatstvu, što značajno ograničava analizu.

Na koncu valja istaknuti i ništa manje važan aspekt fiskalne politike koja, kako je elaborirano kroz poglavlje 3.6.2., kroz definiranje visine poreza i trošarina na naftne derivate (prihodi od trošarina na naftne derivate čine oko 10% ukupnih poreznih prihoda) direktno utječe na trošak potrošnje istih. Trošarine na naftne derivate u RH blago su ispod EU prosjeka. No, zahvaljujući visokoj stopi PDV-a od 25%, dio koji hrvatski građani plaćaju na ime poreza na naftne derivate je veći od EU prosjeka. Na tragu navedenog je važno istaknuti i činjenicu da stanovnici SAD-a plaćaju gotovo upola niže maloprodajne cijene naftnih derivata u odnosu na europske, pa tako i hrvatske građane, jer udio poreza i trošarina u finalnim cijenama goriva SAD-u čini do 20% (*EIA, 2018*), a u EU, pa tako i RH, više od 50% finalne cijene (*GIZ, 2014*). Ovo je važno u kontekstu usporedivih istraživanja mahom rađenih u SAD-u (*Lettau i Ludvigson, 2001; Mehra i Petersen, 2005; Odusami, 2010*).

Zbog navedenog, sugestija je za daljnje istraživanje sagledati na koji način osobna potrošnja reagira na promjene cijena naftnih derivata, a ne sirove nafte. Cijene naftnih derivata na našem se tržištu mijenjaju ne samo kao posljedica kretanja svjetske cijene nafte, već i promjena visine poreza i trošarina, zbog čega uglavnom, u odnosu na svjetske cijene nafte, cijene derivata sporije rastu, ali i sporije padaju. Ne smije se zaboraviti ni utjecaj tečaja USD u odnosu na HRK, zbog čega bi bilo poželjno kao input u istraživanju koristiti krajnje cijene naftnih derivata izražene u domaćoj valuti. U prilog navedenom, kao i istraživanju na razini pojedinog gospodarstva, može se navesti i razlika u kretanju izdataka za prijevoz u zemljama EU (vidjeti Tablicu 3.4.2.) koji su iznimno heterogeni. Ova se heterogenost, barem djelomično, anulira kada se kao input koriste cijene nafte. Na tom tragu su i zaključci istraživanja *Zhang i Broadstock (2014)* koji, iako donose zaključak o asimetričnom utjecaju cijena nafte na osobnu potrošnju u analiziranim gospodarstvima, ističu razlike u jačini, a u pojedinim slučajevima i smjeru utjecaja. Analizirajući utjecaj cijena nafte na potrošnju kućanstava u Kini (2000:Q1 - 2012:Q3), *Zhang (2014)*, između ostalog, konstatira i da su zaključci istraživanja utjecaja naftnih šokova na potrošnju na agregatnoj razini prilično nejasni. Navedeno pojašnjava činjenicom da nisu sva dobra koja se u gospodarstvu konzumiraju u jednakoj mjeri povezana s cijenama nafte.

Naslanjajući se na konstataciju o direktom i indirektnom utjecaju cijena nafte na potrošnju, *Bokan et al. (2018),* koji su proveli analizu utjecaja cijena nafte na osobnu potrošnju u euro zoni (2005-2015), navode kako kućanstva potroše/kupuju trećinu ukupne količine naftnih derivata direktno, dok se preostali dio naftnih derivata angažira u sektorima koji proizvode ostale neenergetske proizvode/usluge. Indirektan se efekt rasta cijena nafte tako rasprostire kroz utjecaj na proizvodne troškove navedenih sektora koji, ako nisu u mogućnosti prebaciti teret rasta proizvodnih troškova u cijelosti na krajnje potrošače, pribjegavaju smanjenju nadnica i/ili profita. Isti autori, nadalje, navode kako promjene u relativnim cijenama uvoza i izvoza, odnosno u uvjetima razmjene, utječu na osobnu potrošnju, a potom ukazuju na evidentan negativan utjecaj cijena nafte na uvjete razmjene u euro zoni (prema *Backus i Crucini, 2000,* isti je prisutan i globalno). S obzirom na navedenu konstataciju, kao preporuka za daljnje istraživanje zanimljivo bi bilo istražiti na koji način cijene nafte utječu na uvjete razmjene u RH, a posredno, preko utjecaja na kupovnu moć, i na osobnu potrošnju, imajući pri tome na umu da je i odnos cijena nafte i uvjeta razmjene podložan promjenama (kao rezultat promjena u stupnju energetske intenzivnosti/efikasnosti potrošnje i proizvodnje dobara/usluga).

Konačno, valja navesti i uloge očekivanja i učenja na koje se u svom istraživanju (opet na SAD-u) referira *Milani (2009)*. Autor ističe kako očekivanja determiniraju odluke potrošača pa tako i cijene nafte utječu na njihova očekivanja glede kretanja budućih razina inflacije i BDP-a. Kroz proces generiranja veće količine informacija (učenje) o kretanjima cijena nafte, usklađuju se i očekivanja potrošača, što može utjecati i na uzorke potrošnje. Na tragu ove konstatacije posebnu važnost imaju „neočekivani“ naftni šokovi. Brojni novinski natpisi iz siječnja 2012. isticali su kako su „*cijene svih benzina probile psihološku granicu od 10kn*“ (*Jutarnji list, 2012*[195]). To je bio prvi puta od samostalnosti RH da su cijene derivata premašile navedeni prag. Nakon toga je logična korekcija očekivanja i proces učenja od strane potrošača pri čemu isti apsolviraju cijene više od 10kn kao „normalne“ (očekivane). Jednom kada se probije psihološka granica (a važan utjecaj imaju i mediji koji je proklamiraju), ona to prestaje biti, odnosno ista se korigira na više. Tako je već u veljači iste godine tadašnji ministar financija Linić izjavio da „*za nas cijena od 12 kuna predstavlja alarm jer je vrlo problematična i za građane i za gospodarstvo*” (*Poslovni dnevnik, 2012*[196]). Navedena psihološka granica još uvijek nije probijena. Probijanje ove granice zasigurno bi izazvalo snažnije reakcije potrošača u vidu

[195]https://www.jutarnji.hr/vijesti/hrvatska/od-ponoci-svi-benzini-probili-psiholosku-granicu-od-10-kuna/1634364/
[196] http://www.poslovni.hr/vijesti/linic-cijena-benzina-od-12-kuna-je-za-nas-alarmantna-197448

utjecaja na njihovu potrošnju i/ili strukturu iste (jer dolazi do rasta cijene na, dotada, neviđenu razinu). Važna je svakako i njihova percepcija o očekivanom trajanju navedene promjene (visokih cijena) kao i period unutar kojeg dolazi do pozitivne korekcije cijene (što je kraći period unutar kojeg raste cijena, time je veći efekt iznenađenja).

4.5.5. Utjecaj cijena nafte na investicije

Korištenjem podataka o realnim investicijama, realnom BDP-u, realnoj kamatnoj stopi i pokazateljima cijena nafte (1996:Q1-2015:Q4), procijenjen je i utjecaj cijena nafte na realne investicije.

Kako se čini, realne investicije, barem inicijalno, statistički značajno pozitivno reagiraju na rast realnih cijena nafte. U tijeku ekonometrijske provjere postavljene hipoteze, pozornost je u konačnici usmjerena na pokazatelj realnih cijena nafte, kod kojeg je i prethodno detektirana Granger uzročnost u smjeru prema realnim investicijama, a koji se temeljem kriterija za odabir najprimjerenijeg pokazatelja cijena nafte pokazao optimalnim pokazateljem.

Granger uzročnost u smjeru od pokazatelja cijena nafte prema realnim investicijama uočena je kod DLOIL i SOPD pokazatelja (na razini od 5% odnosno 10% signifikantnosti). VAR model s realnom cijenom nafte ukazao je na pozitivan utjecaj varijable DLOIL na realne investicije u prva dva tromjesečja nakon inicijalnog šoka, a gotovo identična reakcija realnih investicija, točnije varijable DLINV, je i kod pokazatelja NOPI4, MORK+ i SOPD. Važno je ipak naznačiti da, nakon 5, odnosno 6 tromjesečja, cijene nafte (DLOIL, MORK+, SOPI i SOPD) ipak statistički značajno negativno utječu na investicije. Promatrajući jačinu pozitivnog, odnosno negativnog utjecaja cijena nafte na investicije, može se uočiti nešto jači negativni utjecaj od pozitivnog. No, eventualna razlika u korist negativnog utjecaja je skromna. Zbog navedenih se rezultata **hipoteza H5: Promjene cijena nafte statistički značajno utječu na kretanje investicija, prihvaća**.

Posebno je zanimljiva reakcija realnih investicija na SOPI i SOPD, gdje je utjecaj šoka u navedenim varijablama negativan u oba slučaja. To govori u prilog tezi da rast neizvjesnosti (volatilnosti) smanjuje investicije neovisno o tome jesu li cijene nafte padale ili rasle. Navedeni se rezultat može dovesti u vezu sa zaključcima *Eldera i Serletisa (2009; 2010)* koji, procjenjujući reakciju agregatnih investicija na promjene cijena nafte, konstatiraju da povećana neizvjesnost (koju impliciraju i SOPI i SOPD pokazatelji) vezana uz promjene cijena nafte

umanjuje sve oblike investicija. Na koncu su ipak informacijski kriteriji, kao i analiza Granger uzročnosti, iskristalizirali pokazatelj realne cijene nafte (DLOIL) kao najprimjereniji.

Dekompozicija varijance pokazuje kako kretanje DLOIL pojašnjava gotovo 20% kretanja prognostičke greške realnih investicija, dok je navedeni udio još i veći kod modela s preostalim pokazateljima cijena nafte. Nužno je također naznačiti da se, za razliku od ostalih analiziranih makroekonomskih varijabli, prevladavajući dio varijabilnosti varijable realnih investicija ne može protumačiti prethodnim kretanjem same varijable već preko ostalih varijabli u sustavu. Pri tome se visokih 10% varijabilnosti varijable DLINV već u drugom tromjesečju nakon šoka može tumačiti kretanjem cijena nafte (u prvim periodima udio nafte je veći od udjela BDP-a u pojašnjavanju varijance prognostičke greške varijable DLINV). Ovime do izražaja dolazi činjenica da se uzroci varijabilnosti investicija teže detektiraju, nego li je to slučaj kod ostalih makroekonomskih pokazatelja. U prilog istome, na tragu konstatacija *Dixit i Pindyck (1994)* i *Chirinko (1993)*, govori i skroman udio varijabilnosti realne kamatne stope u pojašnjavanju varijance prognostičke greške realnih investicija. U prilog varijabilnosti pokazatelja realnih investicija govori i ranija kvalitativna analiza istih (vidjeti Grafikon 3.5.3.) gdje je komponenta realnih investicija (u odnosu na preostale komponente realnog BDP-a) pokazala najviši stupanj volatilnosti; najviši rast prije krize (2008. godine) i najveći pad nakon njenog početka.

Snažna veza realnog BDP-a i realnih investicija vidljiva je i kroz analizu Granger uzročnosti koja pokazuje njihov obostrani utjecaj. Kod svih procijenjenih VAR modela, uz 1% signifikantnosti, javlja se i Granger uzročnost u smjeru od realnog BDP-a[197], kao i od (teorijski očekivano) realne kamatne stope, prema realnim investicijama. S obzirom na navedeno, a imajući na umu da je dokazan utjecaj cijena nafte na realni BDP kao i na realne investicije, efekt promjena cijena nafte moguće se prelijeva na realne investicije i posredno, putem utjecaja na realni BDP. U svim procijenjenim VAR sustavima detektirana je statistički značajna veza između realnog BDP-a i realnih investicija, što je u skladu s teorijski očekivanim procikličkim karakterom investicija. Ovdje je važno napomenuti i detektiran statistički značajan negativan utjecaj realne kamatne stope na realni BDP (u svim procijenjenim VAR sustavima) koji, kada

[197] Kod VAR modela sa DLOIL, MORK+/MORK- i SOPI/SOPD pokazateljima evidentirana je obostrana (↔) Granger uzročnost između realnog BDP-a i realnih investicija.

je riječ o utjecaju realne kamatne stope na realne investicije, nije baš tako eksplicite vidljiv u svim modelima.

Za razliku od izrazito skromne količine postojećih istraživanja utjecaja cijena nafte na realne investicije na agregatnoj razini, ovo istraživanje sugerira inicijalnu pozitivnu vezu, te tek naknadnu negativnu reakcije investicija na promjene cijena nafte (što bi prethodno navedena istraživanja sugerirala). Ovakav se rezultat može pojasniti relativno snažnim realnim rastom hrvatskog gospodarstva u trećem mileniju, sve do 2008. godine, unatoč rastu cijena nafte. S obzirom na blisko kretanje realnog BDP-a i realnih investicija, rezultat se može pojasniti navedenim rastom cijena nafte koji je posljedica snažne globalne gospodarske aktivnosti, a isti u kratkom roku, prema *Kilian (2009) i Cashin et al. (2014),* imaju pozitivne rezultate na realni rast zemalja uvoznica nafte. Evidentno je da na primjeru RH, utjecaj cijena nafte na realne investicije posredno doprinosi utjecaju cijena nafte na realni BDP.

Vrijedno bi bilo istražiti pojedine segmente investicijske potrošnje krećući od pretpostavke da ne reagiraju svi sektori na promjene cijena nafte na isti način (*Elder i Serletis, 2010*). Ako se pojedine kategorije kreću u suprotnim smjerovima (npr. investicije u sektoru naftne industrije prate rast cijena nafte, što nije slučaj u ostalim sektorima) tada će efekti utjecaja cijena nafte na realne investicije na agregatnoj razini biti znatno drugačiji. Nadalje, uputno bi kao input bilo koristiti maloprodajne cijene naftnih derivata na domaćem tržištu. Važno je također, na tragu konstatacija *Crompton i Wu (2005),* uzeti u obzir i industrijsku strukturu, odnosno nacionalne specifičnosti. Upravo tako i *Wang et al. (2017)* ističu kako su u Kini snažnije reakcije privatnih poduzeća (investicija) od reakcija javnih poduzeća (investicija) na promjene cijena nafte, a u Hrvatskoj je, u odnosu na EU28, prisutan veći udio javnih u odnosu na privatne investicije (*Eurostat, Investment share of GDP by institutional sectors, % of GDP, 2018*).

Kao sugestija za daljnje istraživanje svakako bi bilo interesantno ispitati i utjecaj cijena nafte na investicijske odluke na mikrorazini, kako je i slučaj u rastućem broju usporedivih istraživanja. Na ovaj se način ujedno mogu razlučiti i eventualne razlike u načinu na koji reagiraju javne i privatne investicije, kao i razlike u reakcijama investicija ovisno o pripadnosti pojedinom sektoru gospodarstva.

4.5.6. Asimetričnost prilagodbe cijena naftnih derivata cijeni nafte

Kako bi se provjerio utjecaj cijena nafte na cijene naftnih derivata, korišteni su podaci (2000:M01-2015:M12) o prosječnim mjesečnim cijenama naftnih derivata Eurodizel (u početnom dijelu analiziranog perioda INA Dizel gorivo) i Eurosuper 95 (u početnom dijelu analiziranog perioda INA BMB 95) bez poreza i trošarina (u kn/l) kao i cijena nafte denominirana u HRK po litri.

Rezultati analize dugoročnog odnosa upućuju na zaključak da postoji statistički značajan dugoročan odnos između cijena sirove nafte i cijena Eurodizela i Eurosupera 95. Konkretnije, kod obje jednadžbe pokazalo se da pri generiranju maloprodajne cijene (bez poreza i trošarina) Eurosupera 95 0,66 kn/l, odnosno 0,67 kn/l kod Eurodizela je dio cijene koji ne ovisi o kretanjima cijena nafte. S druge strane, a kao djelomična posljedica navedenog, parametri kojima se procjenjuje stupanj prilagodbe cijena naftnih derivata cijenama nafte impliciraju da je prilagodba nepotpuna (manja od 100%). Time se potvrđuje odstupanje strukture tržišta maloprodaje naftnih derivata od tržišne strukture savršene konkurencije. Pri tome je dugoročni stupanj prilagodbe cijena Eurosupera 95 cijenama nafte na razini 69,9%, a Eurodizela 75,3%. Osim tržišne strukture, odstupanje od potpune prilagodbe cijena naftnih derivata cijenama nafte može se objasniti i asimetrijom informacija, troškovima rafiniranja, skladištenja, distribucije i marketinga, kao i profitnim maržama. Na globalnoj razini također se trguje i derivatima nafte (ne samo sirovom naftom). Prema *Bamberger i Pirog (2008)*, nerijedak je slučaj kretanje cijena naftnih derivata i u suprotnom smjeru od kretanja cijena sirove nafte, a što autori pojašnjavaju vremenskim (ne)prilikama, štrajkovima ili pak diskontnim kampanjama. Sve navedeno za posljedicu može imati nepotpunu prilagodbu cijena naftnih derivata cijenama nafte.

Temeljem procijenjenih asimetričnih jednadžbi kratkog roka analiza je finalizirana Wald testom razlike u brzinama prilagodbe cijena naftnih derivata njihovoj srednjoj vrijednosti kada su iste ispod odnosno iznad ravnotežne razine. Analiza je pokazala da (iako su temelj za izračun Wald testa bili koeficijenti statistički značajni na razini signifikantnosti od 1%) razlika u procijenjenim koeficijentima za Eurodizel nije statistički značajna, odnosno da je ista statistički značajna za Eurosuper 95, ali tek uz 10% signifikantnosti. Navedeno podrazumijeva da ne postoji asimetrija u prilagodbi cijena Eurodizela cijenama nafte. Analiza cjenovne asimetrije za Eurosuper 95 je pokazala da je potrebno više vremena (2,34 mjeseca) za prilagodbu dugoročnoj ravnoteži kada su cijene iznad dugoročne ravnoteže, nego li kad su cijene ispod ravnotežne (u

kom slučaju je potrebno 1,39 mjeseci) što upućuje na postojanje cjenovne asimetrije. Ipak, s obzirom da je navedeni rezultat statistički značajan tek uz razinu od 10% signifikantnosti, a istovremeno je dokazano da ne postoji statistički značajna cjenovna asimetrija u prilagodbi cijena Eurodizela (koji je sve zastupljeniji u ukupnoj prodaji) može se zaključiti da provedena analiza upućuje na **odbacivanje hipoteze H6: Cijene naftnih derivata asimetrično reagiraju na promjene cijena nafte.**

Navedeno se može dovesti u vezu sa zaključcima *Godby et al. (2000), Bettendorf et al. (2002), Galeotti et al. (2003), Bachmeier i Griffin (2003)* koji također odbacuju hipotezu cjenovne asimetrije na analiziranim tržištima naftnih derivata.

Rezultati istraživanja AZTN-a (navedenog u sklopu poglavlja 3.6.1. Cijene naftnih derivata) za period od veljače 2014. do veljače 2015. (neposredno nakon potpune liberalizacije maloprodajnog tržišta naftnih derivata) ukazuju na postojanje fenomena cjenovne asimetrije u brzini prilagodbe cijena naftnih derivata cijenama nafte, ne samo u Hrvatskoj već i u zemljama u njenom neposrednom okruženju. U odnosu na prethodno iznesene zaključke empirijske provjere hipoteze H6 riječ je o oprečnim rezultatima. Razlika među rezultatima istraživanja AZTN-a i ovog istraživanja (koje nije potvrdilo postojanje asimetrije) mogla bi se ponajprije pojasniti vremenskim obuhvatom, koji je kod AZTN-a znatno kraći. Također, razlika u rezultatima mogla bi se pojasniti i činjenicom da su kroz veći dio promatranog perioda (2000.-2015.) cijene naftnih derivata u RH formirane uz relativan nadzor politike i to prema, sada nevažećem, Pravilniku o utvrđivanju najviših maloprodajnih cijena naftnih derivata (NN 145/12, 18/13 i 62/13). Pri tome je i Vlada Republike Hrvatske kao suvlasnik najjače domaće energetske kompanije INA-e posredno mogla utjecati na formiranje krajnjih cijena naftnih derivata. Također, u skladu s navedenim Pravilnikom, kroz promatrani period cijene derivata su se mijenjale na tjednoj bazi (ne na dnevnoj kao što je uobičajeno na ostalim tržištima), a u jednom periodu (od 03.05.2010. do 20.02.2014.) i na dvotjednoj bazi, što u svakom slučaju može iskriviti sliku stvarnog stanja na tržištu. Od 20. veljače 2014. godine na snazi je Zakon o tržištu nafte i naftnih derivata (NN 19/14) kojim je van snage stavljen dotada važeći Pravilnik o utvrđivanju najviših maloprodajnih cijena naftnih derivata (NN 145/12, 18/13 i 62/13), te je njime omogućeno potpuno slobodno formiranje cijena naftnih derivata na predmetnom tržištu, na dnevnoj bazi, iako navedeno nije u stvarnosti zaživjelo.

Nadalje, za period od veljače 2014. do konca 2018. godine, HNB provodi ECM metodologijom istraživanje cjenovne asimetrije naftnih derivata, dizela i motornog benzina u RH (*HNB, Makroekonomska kretanja i prognoze, 2018*) pri čemu se u istom konstatira da se glavnina prilagodbe cijene goriva cijenama nafte ostvaruje s vremenskim odmakom od dva tjedna (uglavnom zbog ustaljene poslovne prakse promjena cijena derivata jednom tjedno). Nadalje, istraživanje ukazuje na nepostojanje cjenovne asimetrije u prilagodbama cijena dizela cijenama nafte, što je usporedivo i sa zaključcima ovog istraživanja. Navedeno se može pojasniti i time što su kupci dizelskih goriva često industrijski potrošači koji kupnjom na veliko mogu potencijalno pregovarati i cijene s dobavljačima, a moguće je i generiranje tzv. strateških rezervi (kupnja kada su cijene niže, neovisno o trenutnim potrebama) od strane istih (kao i neindustrijskih velikih potrošača, npr. bolnica, škola i sl.) koje potencijalno obeshrabruje poslovne subjekte da se ponašaju asimetrično prilikom prilagodbe cijena dizelskih goriva.

Što se tiče cijena benzina, rezultati HNB-a ukazuju na moguće postojanje pozitivne cjenovne asimetrije, ali se navedena hipoteza prihvaća tek uz 10%tnu razinu signifikantnosti zbog čega se zaključuje da postoje naznake asimetrije, ali ista nije statistički značajna. Navedeni su rezultati u potpunosti usporedivi s ovdje ponuđenima. Konačno, ali ne manje važno, navedeni su rezultati generirani primjenom cijena derivata bez poreza i trošarina (kao i u ovom istraživanju), ali i primjenom krajnjih maloprodajnih cijena. Pri tome HNB ističe da i rezultati generirani primjenom krajnjih cijena s uključenim porezima i trošarinama, upućuju na usporedive zaključke.

Asimetrična cjenovna prilagodba kao tržišni fenomen, ako i postoji na hrvatskom maloprodajnom tržištu naftnih derivata, očigledno nije ravnomjerno vremenski distribuirana; događa se u pojedinim trenutcima ili kraćim vremenskim periodima zbog čega ju je još teže „uhvatiti“. Kako navodi *Perdiguero-Garcia (2013)* istraživanja koja koriste duže vremenske nizove lakše odbacuju hipotezu o postojanju asimetrije. Analiziranje duljih vremenskih perioda, kao što je u ovom istraživanju slučaj, može stoga biti kontraproduktivno jer se na taj način obuhvaćaju periodi različitih tržišnih uvjeta i obrazaca ponašanja na tržištima, što na koncu rezultira nemogućnošću donošenja ispravnih zaključaka. U tom smislu, preporuka je provesti istraživanje na kraćim vremenskim nizovima koji uključuju tek nekoliko posljednjih godina, prvenstveno od 2014. godine naovamo, a posebno bi bilo interesantno usporediti period prije i nakon veljače 2014. godine kada je i formalno potpuno liberalizirano tržište naftnih derivata. Ovakva analiza bi ujedno ukazala i na efekte potpune liberalizacije tržišta maloprodaje naftnih

derivata, odnosno potencijalne koristi iste za krajnje potrošače. Rezultati postojećih istraživanja, uključujući i ovo, zasada ne upućuju na zaključak da je potpuna liberalizacija polučila pozitivne efekte za krajnje potrošače.

U prilog navedenom mogu se istaknuti i rezultati metaistraživanja *Cook i Fosten (2019)* koji uključivanjem recentnijih podataka kako bi provjerili zaključke ranijih istraživanja dobivaju potvrde o postojanju cjenovne asimetrije, kako na tržištima dizela tako i motornog benzina. Ipak, isti autori ističu i značajne oscilacije u odnosu na korištenje alternativnih metodoloških pristupa što se i kod ovdje prikazanog istraživanja može navesti kao svojevrsno ograničenje, odnosno preporuka za daljnje istraživanje.

Kao ključno ograničenje istraživanja, valja dodati i frekvenciju i stupanj agregiranosti podataka. Ispravna frekvencija podataka morala bi biti istovjetna frekvenciji promjena cijena na tržištima naftnih derivata, no takvi podaci (pogotovo ponderirani prosjeci) nisu dostupni. Kako je uglavnom riječ o dnevnim promjenama cijena nafte, točni se zaključci mogu donijeti isključivo na temelju istraživanja nad dnevnim vremenskim nizovima cijena. Međutim, u Hrvatskoj se cijene naftnih derivata i dalje ne mijenjanju na dnevnoj bazi. Uz navedeno, potrebno je koristiti i prostorno dezagregirane podatke, na razini benzinskih postaja, jer je nelogično pretpostaviti da se svi energetski subjekti na tržištu ponašaju potpuno jednako. Da bi ovo bilo moguće, istraživanje bi trebalo provesti nad dnevnim nizovima podataka po različitim benzinskim postajama na pojedinim mikrolokacijama (gradovima i regijama) jer se prostornim agregiranjem podataka, koje je preduvjet za dobivanje korištenih prosječnih tjednih cijena, vrlo lako može „prikriti“ cjenovna asimetrija na razini pojedinog energetskog subjekta. U prilog navedenom mogu se navesti i zaključci *Reilly i Witt (1998), Bachmeier i Griffin (2003), Balaguer i Ripollés (2012), Douglas (2010) i Perdiguero-Garcia (2013*) koji ističu kako vjerojatnost potvrđivanja, odnosno odbacivanja hipoteze o postojanju cjenovne asimetrije, između ostalog, ovisi o frekvenciji korištenih podataka, ali i tipu korištene metodologije. Dodatna kritika korištenim podacima je i činjenica da se prosječne cijene ne dobivaju ponderiranim prosjekom pa se time ne uvažava ni tržišni udio pojedinog subjekta, što je također iznimno važno.

U konačnici, uputno je temeljem dosadašnjih empirijskih provjera i teorijskih spoznaja zaključiti da asimetrična cjenovna prilagodba cijena naftnih derivata nije kontinuirano obilježje

tržišta naftnih derivata, već se javlja u pojedinim, kraćim vremenskim intervalima Zbog toga se mogućnost njenog postojanja nikako ne bi smjela u potpunosti odbaciti.

4.5.7. Ograničenja provedenog istraživanja i preporuke za daljnje istraživanje

Ograničenja provedenog istraživanja mogla bi se kategorizirati na opća (primjenjiva na cjelokupno istraživanje) i specifična (primjenjiva na empirijske provjere pojedinih hipoteza) pri čemu su potonja u većoj mjeri iznijeta u prethodnom poglavlju. U nastavku slijedi osvrt na opća ograničenja provedenog istraživanja.

S obzirom na temeljni cilj predloženog istraživanja, jedan od ključnih elemenata istraživanja je način izražavanja (promjena) cijena nafte. Vodeći se usporedivim istraživanjima obrađene tematike u svijetu, i u ovom je istraživanju kao temeljni input korištena cijena barela nafte u USD. Kako je kroz elaboraciju teme disertacije i pojašnjeno, nafta se tek u minornom udjelu troši u nerafiniranom obliku. Ovakav pristup u istraživanjima opravdava se stavom da promjene cijena naftnih derivata ne odražavaju samo globalne promjene cijena nafte, već i utjecaj fiskalne politike pojedinog gospodarstva, što se nikako ne smije dovoditi u vezu s globalnim kretanjima cijena nafte. Promjene cijena nafte utječu na uvoznu vrijednost nafte koja se, nadalje, pretače na krajnje cijene. Ipak, imajući navedeno u vidu, zanimljivo bi bilo istražiti na koji način konačne maloprodajne cijene naftnih derivata utječu na pojedine makroekonomske pokazatelje, prije svega na osobnu potrošnju.

Razlog korištenja cijena sirove nafte u istraživanju proizlazi također iz potrebe da se kao inicijalni šok makroekonomskim varijablama u RH koristi pokazatelj istovjetan onome u usporedivim istraživanjima na drugim kako razvijenim tako i gospodarstvima u razvoju. Činjenica je da maloprodajne cijene naftnih derivata uvelike ovise o fiskalnoj, odnosno poreznoj, politici, što je i prikazano međunarodnom usporedbom cijena naftnih derivata (vidjeti poglavlje 3.6.3.). Navedena činjenica implicira da su cijene istih u Europi, pa tako i Hrvatskoj, značajno opterećene porezima i trošarinama (posebice u odnosu na SAD) koji čine više od polovine maloprodajne cijene. Ipak i ovdje treba imati na umu ograničenja u vidu dostupnosti podataka jer bi optimalno bilo korištenje prosječne maloprodajne cijene goriva i maziva za što je potrebno ponderirati udio potrošnje pojedinog derivata na mjesečnoj bazi, podatak koji na ovoj frekvenciji ne postoji. Nadalje, iako je istraživanje pokazalo da su cijene naftnih derivata

blisko pratile kretanja cijena nafte u analiziranom periodu, činjenica je da je potpuna liberalizacija tržišta naftnih derivata stupila na snagu tek 2014. godine zbog čega će tek istraživanja koja uključuju 2014. kao početni period analize moći nedvojbeno otkriti stvarnu prirodu reakcije cijena naftnih derivata na promjene globalnih cijena nafte. Konačno, ne manje važno, zanimljivo bi bilo istražiti, na tragu prakse *Cuñado i Pérez de Gracia (2003),* utjecaj naftnih šokova na domaće gospodarstvo kada je isti iskazan u domaćoj valuti. Usporediva istraživanja uključuju i efektivni devizni tečaj kao jednu od varijabli, što je učinjeno i u ovom istraživanju. Ipak, dolar, kojim se plaća nafta, čini tek manji dio efektivnog deviznog tečaja RH te kao takav ne odražava u najboljoj mjeri promjene bilateralnog tečaja USD/HRK, što u stvarnosti determinira trošak uvoza nafte/naftnih derivata.

Samo pitanje odabira pokazatelja kojim bi se iskazale cijene nafte, iako se u ovom istraživanju nastojalo donekle minimizirati odabirom nekoliko različitih pokazatelja, još uvijek „muči“ renomirane znanstvenike u ovom području. Tako je moguće referirati se i na diskusiju *Kiliana i Vigfussona (2011b) i Hamiltona (2011)* o primjerenosti pokazatelja realne/nominalne cijene nafte, čime bi se trebale cijene nafte deflacionirati, odnosno jesu li možda krajnje cijene naftnih derivata primjereniji pokazatelj, posebno kod ispitivanja njihovog utjecaja na potrošnju (*cf. Edelstein i Kilian, 2009; Ramey i Vine, 2010*). U potonjem slučaju šok koji bi se analizirao nije u stvarnosti naftni šok jer uvelike ovisi o fiskalnoj politici koja u velikoj mjeri diktira krajnje cijene naftnih derivata. Imajući na umu tvrdnje *Narayan et al. (2014),* kako nositelji politike imaju bolje razumijevanje načina kako funkcionira njihovo gospodarstvo, optimalno bi bilo ponuditi istima modele, odnosno predikcije utjecaja kako realnih tako i nominalnih naftnih šokova na gospodarstvo, a potom im prepustiti odluku o relevantnosti jednih spram drugih.

Može se konstatirati i da je duljina korištenih vremenskih nizova u istraživanju relativno skromna, posebice kada je riječ o vremenskim nizovima tromjesečnih podataka. Kada se ispituje dugoročan odnos dvaju (ili više) varijabli koristeći pritom relativno skromne duljine vremenskih nizova, rezultat će biti ili nemogućnost dobivanja statistički značajnih rezultata ili generiranje modela s manjim brojem vremenskih odmaka (unutar kojih se ne može „zarobiti“ stvaran odnos među istraživanjem obuhvaćenim varijablama) koji ne pokazuje na adekvatan način dugoročan odnos varijabli. Ovo posebno dolazi do izražaja uslijed značajnih odstupanja vrijednosti varijabli unutar odabranog perioda analize (primjerice kriza 2008.) kao i kada dolazi do promjene u prirodi odnosa između pojedinih varijabli.

Nadalje, *Hamilton (1996), Hamilton i Herrera (2004),* i *Edelstein i Kilian (2007)* ističu kako se primarni efekt naftnog šoka na realni output događa unutar perioda od godine dana nakon šoka ističući tako važnost obuhvaćanja minimalno 4 tromjesečja (ili 12 mjeseci) u modele čak i kada informacijski kriteriji sugeriraju drugačije. U ovom se istraživanju poštivala ekonometrijska procedura pa, kao posljedica, nije udovoljeno navedenom zahtjevu (npr. za provjeru H1 korišteni su modeli s dva, odnosno jednim vremenskim odmakom). Shodno navedenom, kao preporuka za daljnje istraživanje, mogao bi se modelima („na silu") obuhvati veći broj vremenskih odmaka.

Kao preporuka za daljnje istraživanje mogu se sugerirati i alternativna metodološka rješenja. Razlog za isto krije se prvenstveno u navodima nekolicine spomenutih istraživanja (*Kilian, 2009, Cashin et al. 2014*) koji impliciraju potpuno drugačiju reakciju gospodarstva na naftne cjenovne šokove ovisno o njihovom izvoru (jesu li isti posljedica promjena na strani ponude nafte, potražnje vođene globalnom ekonomskom aktivnošću ili špekulacija). Stoga bi ključna preporuka bila sagledati reakciju gospodarstva na naftne šokove na način da se isti kategoriziraju s obzirom na izvor promjene cijena nafte.

Nadalje, problem koji treba navesti je svakako i prisutna heteroskedastičnost u korištenim vremenskim nizovima koja se, iako se pokušava minimizirati, ne može izbjeći. Posljedica je to izrazitih fluktuacija kako cijena nafte tako i makroekonomskih pokazatelja RH, bilo da je riječ o realnom BDP-u i njegovim komponentama, bilo o, primjerice, stopama nezaposlenosti. Konačno, svakako treba imati na umu i mogućnost grešaka u korištenim vremenskim nizovima koje potječu iz procesa proizvodnje statističkih podataka [198].

[198] Nekoliko je tipova pogrešaka koje potječu iz svih različitih procesa proizvodnje statističkih podataka te je razvijena tipologija pogrešaka. Pogreške uzorkovanja odnose se samo na uzoračke ankete, a nastaju zbog odabira, najčešće slučajnog, samo jednog podskupa populacije. Pogreške koje nisu uzrokovane uzorkovanjem odnose se na sve statističke procese, a može ih se razvrstati u sljedeće kategorije: pogreške obuhvata, pogreške mjerenja, pogreške zbog neodgovora i pogreške u procesiranju (*DZS, Eurostat priručnik za izvještaje o kvaliteti Europskog statističkog sustava, 2009, str. 30*).

5. ZAKLJUČAK

U sklopu ove doktorske disertacije ispitan je utjecaj cijena nafte na makroekonomske pokazatelje, BDP, inflaciju, nezaposlenost, osobnu potrošnju i investicije u Republici Hrvatskoj u periodu od 1995. do 2015. godine.

U uvodnom je *dijelu* disertacije naznačena problematika provedenog istraživanja naslanjajući se na postojeća istraživanja utjecaja cijena nafte na makroekonomske pokazatelje (prvenstveno BDP) čije je proučavanje rezultiralo konstatacijom o nepostojanju znanstvenog konsenzusa oko mehanizama kao i jačine utjecaja cijena nafte na gospodarstva općenito. Interes istraživanja navedene tematike naslanja se na neupitnu važnost energije općenito u funkcioniranju suvremenog života i nacionalnih ekonomskih tokova, neovisno o stupnju razvijenosti promatranog gospodarstva. Fokus na cijene nafte proizlazi iz istaknute važnosti energije kao proizvodnog inputa kao i značaja nafte kao, još uvijek, najzastupljenijeg energenta, kako globalno, tako i u Hrvatskoj. Štoviše, u istraživanju naznačeni energetski trendovi impliciraju važnost nafte kao najvažnijeg energenta i u budućnosti. Ne manje važno, ovakav tip istraživanja uzima u obzir cijenu nafte spram šire znanstvene rasprave o međuodnosu potrošnje energije i BDP-a koja u potpunosti zanemaruje cjenovni aspekt energije.

Pored navedenog, naznačen je i nezaobilazan problem rastuće uvozne ovisnosti o nafti zbog kojeg su sva gospodarstva koja ovise o njenom uvozu (i/ili uvozu njenih derivata) direktno podložna promjenama njenih cijena na koje ista, nerijetko, nemaju gotovo nikakav utjecaj. Navedeno implicira rast cijena nafte kao vanjski šok za zemlje neto uvoznice nafte, zbog čega je nužno poznavanje reakcije pojedine nacionalne ekonomije na isti kao i mehanizama kojima bi se eventualni negativni efekti mogli učinkovito i pravodobno amortizirati.

Ne manje važno, pregled postojećih istraživanja ukazuje na popriličnu heterogenost utjecaja cijena nafte na različita gospodarstva, pri čemu analizirana gospodarstva nerijetko različito reagiraju na promjene cijena nafte u različitim vremenskim periodima. Nadalje, većina postojećih istraživanja fokusiran je na razvijene ekonomije. Imajući u vidu razlike među ekonomijama, njihova se iskustva (pa ni zaključci tih istraživanja) nikako ne bi trebala neupitno prihvatiti kao primjenjiva i na ostale. Štoviše, čak i navedena istraživanja daju preporuke, prvenstveno nositeljima makroekonomske politike, o uzimanju u obzir šire znanstvene rasprave povezane tematike, a imajući u vidu specifičnosti pojedinog nacionalnog gospodarstva. Nužno

je stoga kontinuirano proučavati međuodnos cijena nafte i makroekonomskih pokazatelja pojedinog gospodarstva uvažavajući postojeće znanstvene spoznaje koje impliciraju da je navedeni odnos podložan promjenama kao posljedica, primjerice, različitih uzroka promjena cijena nafte (šok na strani ponude ili šok na strani potražnje za naftom) kao i promjena nacionalne gospodarske strukture.

U drugom su dijelu disertacije, pod naslovom *Makroekonomski učinci kretanja cijena nafte*, iznesene postojeće znanstvene spoznaje o vezi gospodarskog rasta i energije općenito, a potom je, temeljem relevantnih i recentnih istraživanja, dana i klasifikacija mehanizama utjecaja cijena nafte na gospodarstvo, točnije na pojedine makroekonomske pokazatelje. Konkretno, fokus je usmjeren na utjecaj cijena nafte na gospodarski rast, inflaciju, nezaposlenost, osobnu potrošnju i investicije. S obzirom na brojne specifičnosti, analizirane su ključne karakteristike globalnog naftnog tržišta kao i njihov utjecaj na kretanje globalnih cijena nafte te je izvršena teorijska sistematizacija varijabli pod čijim utjecajem dolazi do promjena cijena nafte. Analiziran je i problem asimetrije u prilagodbi cijena naftnih derivata cijenama nafte (*engl. rockets and feathers)* pri čemu se detaljnim pregledom relevantnih istraživanja, kao i sistematizacijom istih, nastojalo predočiti potencijalne uzroke navedene pojave kao i okolnosti koje potenciraju veću vjerojatnost njene detekcije u uzorku.

Naslanjajući se na prethodno izneseno, u trećem je dijelu disertacije izvršena kvalitativna *Analiza makroekonomskih pokazatelja hrvatskog gospodarstva*. Uzimajući u obzir nužnost uvažavanja nacionalnih specifičnosti, kroz navedeno je poglavlje ponuđen pregled kretanja odabranih makroekonomskih pokazatelja, BDP-a, inflacije, nezaposlenosti, osobne potrošnje i investicija, ali i rezultata znanstvenih istraživanja fokusiranih na kvalitativnu i kvantitativnu analizu njihova kretanja. U posljednjem je dijelu poglavlja izvršene i analiza hrvatskog tržišta naftnih derivata kako bi se iskazala važnost nafte kao energenta u ukupnoj nacionalnoj energetskoj strukturi, uvozna ovisnost o istoj (nafti i naftnim derivatima) kao i mehanizam kreiranja finalnih cijena naftnih derivata. Konačno, izvršena je i usporedba cijena naftnih derivata u međunarodnom kontekstu.

Četvrtim poglavljem, pod naslovom *Istraživanje utjecaja cijena nafte na makroekonomske pokazatelje hrvatskog gospodarstva*, predstavljena je metodologija empirijskog dijela istraživanja, tijek i rezultati ekonometrijske analize, kao i rasprava o istima. Temeljem prethodne teorijske elaboracije obrađene tematike, oblikovan je konceptualni model utjecaja

cijena nafte na makroekonomske pokazatelje u Republici Hrvatskoj. Pri tome su za provjeru definiranih hipoteza istraživanja permutirani različiti pokazatelji cijena nafte, uvažavajući mogućnost različite prirode utjecaja cijena nafte na pojedini makroekonomski pokazatelj. Osvrćući se na navedeni konceptualni model, definirano je šest hipoteza istraživanja čijom se ekonometrijskom analizom ispitao, i djelomično potvrdio, utjecaj cijena nafte na makroekonomske pokazatelje hrvatskog gospodarstva. Navedeni su rezultati sagledani uzimajući u obzir širu znanstvenu raspravu ne samo postojećih znanstvenih istraživanja utjecaja cijena nafte na makroekonomske pokazatelje, već i zaključke relevantnih znanstvenih istraživanja koja su proučavala kretanje analiziranih makroekonomskih pokazatelja u Republici Hrvatskoj. Na taj su način uvažene karakteristike hrvatskog gospodarstva u pojašnjavanju detektiranih međuodnosa kao i izostanka istih.

Hipotezom H1 ispitan je utjecaj cijena nafte na hrvatski BDP pri čemu je potvrđen statistički značajan utjecaj cijena nafte, predstavljen pokazateljem MORK+/MORK- (kao i SOPD), na BDP što implicira asimetričnu reakciju gospodarstva na promjene cijena nafte. Konkretno, analiza je detektirala statistički značajan negativan utjecaj rasta cijena nafte (MORK+) na BDP u prva dva tromjesečja, nakon čega isti postaje pozitivan do kraja trećeg tromjesečja, a potom prestaje biti statistički značajan. Kumulativan utjecaj rasta cijena nafte na BDP može se stoga smatrati i neutralnim, unatoč inicijalnoj negativnoj reakciji na rast cijena nafte. MORK- i SOPD, koji predstavljaju pad cijena nafte, ukazuju na statistički značajnu pozitivnu reakciju BDP-a na pad cijena nafte unutar prva dva tromjesečja; stoga se može konstatirati da unutar analiziranog perioda nisu uočeni negativni efekti rasta cijena nafte na rast hrvatskog BDP-a. Navedeno se može pojasniti niskim udjelom proizvodnog sektora u hrvatskoj proizvodnoj strukturi, padom energetske intenzivnosti i rastom energetske učinkovitosti gospodarstva, kao i činjenicom da se unutar perioda analize rast cijena nafte može ponajviše pojasniti snažnim globalnim gospodarskim rastom (šok na strani potražnje) s kojim je od početka milenija bilo prociklički usklađeno i hrvatsko gospodarstvo. U prilog navedenim rezultatima, pored izvora promjena cijena nafte, mogu se navesti i viši koeficijenti dohodovne elastičnosti potražnje za domaćim naftnim derivatima u odnosu na cjenovnu elastičnost potražnje za istima, a što podrazumijeva da je potražnja za naftom u Hrvatskoj prvenstveno funkcija dohotka, a tek onda njenih cijena.

Utjecaj cijena nafte na inflaciju ispitan je hipotezom H2, pri čemu je dokazan statistički značajan pozitivan utjecaj rasta cijena nafte (predstavljenog rastom nominalnih cijena nafte) na

rast inflacije u Hrvatskoj, iako ograničen na dva mjeseca nakon promjene, nakon čega isti prestaje biti statistički značajan. Navedeno implicira izraženu važnost prve runde odnosno direktnog utjecaja rasta cijena nafte koja se manifestira kroz gotovo trenutačan rast cijena naftnih derivata. Istovremeno je analiza ukazala na značajan utjecaj kanala deviznog tečaja na inflaciju, kao i na kamatnu stopu i novčanu masu, potvrđujući važnost kanala deviznog tečaja u Republici Hrvatskoj.

Hipotezom H3 ispitan je utjecaj cijena nafte na nezaposlenost pri čemu je analiza ukazala na nepostojanje statistički značajne veze. S obzirom na specifičnosti hrvatskog tržišta rada koje uključuju visoku razinu sindikalne gustoće (oko 35%), nisku fleksibilnost tržišta rada, postojanje dugotrajne visoke stope nezaposlenosti (kao i niske zaposlenosti), nisku stopu participacije radne snage te, u kontekstu post-tranzicijskih EU članica, relativno visoke troškove radne snage koji nisu u potpunosti usklađeni s produktivnošću rada, kao i rigidnost na tržištu rada, kako u kontekstu plaća tako i u kontekstu zakonske zaštite zaposlenja, navedeni zaključak je donekle očekivan. Problemi hrvatskog tržišta rada ne mogu se stoga pojasniti kretanjima cijena nafte, a nerijetko ni cikličkim kretanjima gospodarstva.

Empirijska provjera hipoteze H4 potvrdila je nepostojanje statistički značajne veze između cijena nafte i osobne potrošnje. Ovdje je nužno istaknuti ograničenja korištene metodologije zbog kojih je bilo nužno odabrati svega jedan vremenski odmak unutar kojeg je ozbiljnija reakcija potrošnje teško moguća, ali i (ne)dostupnost podataka o raspoloživom dohotku, kao i bogatstvu. Prilična odstupanja vrijednosti korištenih varijabli i relativno skromna duljina korištenih nizova dodatno su otežali provjeru navedene hipoteze. Nadalje, nužno je naznačiti zamijećene strukturne promjene potrošnje koje se ni ne mogu detektirati na agregatnoj razini. Prvenstveno se to odnosi na rast udjela izdataka za prijevoz u ukupnoj potrošnji kao i istovremeni drastičan pad broja novoregistriranih automobila, što se unutar kategorije trajnih potrošnih dobara smatra najosjetljivijom skupinom. Osobna potrošnja stoga nije u promatranom periodu u odnosu na cijene nafte pokazala statistički značajnu reakciju, iako je unutar strukture potrošnje zamjetna prilagodba ponašanja zbog niske cjenovne elastičnosti potražnje na naftnim derivatima.

Hipotezom H5 ispitan je i potvrđen statistički značajan utjecaj cijena nafte na investicije. Iako je analiza ukazala na statistički značajan utjecaj nekoliko različitih pokazatelja cijena nafte na investicije, ista je ukazala na realne cijene nafte kao najprimjereniji pokazatelj, implicirajući

ujedno nepostojanje asimetrije u njihovom međusobnom odnosu. Rezultati analize pokazuju kako investicije, barem inicijalno (unutar prva dva tromjesečja), pozitivno statistički značajno reagiraju na rast cijena nafte (DLOIL, MORK+, NOPI4), nakon čega njihov utjecaj postaje negativan (i izraženiji u odnosu na inicijalnu pozitivnu reakciju), a potom i prestaje biti statistički značajan. Navedeno se može pojasniti važnošću uzroka naftnog šoka. Kada je isti posljedica snažnog globalnog gospodarskog rasta s kojim je prociklički usklađeno domaće gospodarstvo, zbog veće dohodovne od cjenovne elastičnosti potražnje za naftom, raste i realno gospodarstvo, kao i investicije, unatoč rastu cijena nafte. Tako se i negativan efekt rasta cijena nafte na investicije uočava tek kasnije, čak godinu nakon inicijalnog šoka. Pri tom je izuzetno zanimljiva negativna reakcija investicija na SOPI i SOPD pokazatelje koji uvažavaju volatilnost cijena nafte, a pri čemu je reakcija investicija istovjetna neovisno o korištenom pokazatelju implicirajući važnost rasta volatilnosti cijena spram važnosti smjera u kojem se iste kreću. Konačno, s obzirom da je u odnosu na prethodno analizirane makroekonomske pokazatelje upravo kod investicija uočen najvišu stupanj varijabilnosti, upravo cijene nafte u značajnoj mjeri (do 20%) doprinose tumačenju navedenih odstupanja. S obzirom na detektiranu uzročnu vezu BDP-a i investicija, utjecaj cijena nafte na investicije odvija se neposredno i posredno, putem BDP-a.

Konačno, hipotezom H6, istraženo je postojanje cjenovne asimetrije između cijena nafte i cijena Eurodizela i Eurosupera95. Analiza cjenovne asimetrije za Eurosuper 95 je ukazala na postojanje cjenovne asimetrije, ali tek uz razinu od 10% signifikantnosti, a istovremeno je dokazano da ne postoji statistički značajna cjenovna asimetrija u prilagodbi cijena Eurodizela (koji je sve zastupljeniji u ukupnoj prodaji). Zbog toga je donesen zaključak o odbacivanju hipoteze. Ovakav rezultat bi podrazumijevao efikasno funkcioniranje tržišta i svojevrstan „f*air play*“ od strane energetskih subjekata na domaćem tržištu maloprodaje. Ipak, nužno je istaknuti, temeljem šire elaboracije postojećih istraživanja navedene tematike, da se cjenovna asimetrija na tržištima javlja, a samim time i lakše detektira, unutar manjih vremenskih perioda, odnosno ista se ne smatra kontinuiranim obilježjem tržišta. Zbog navedenog je nužno kontinuirano provoditi provjeru iste, posebice u kraćim vremenskim periodima i to nad što višom frekvencijom podataka (usklađenom s frekvencijom promjena cijena nafte kao temeljnog inputa).

Istraživanje utjecaja cijena nafte na makroekonomske pokazatelje u Hrvatskoj pokazalo je kako je direktan efekt naftnog šoka na nacionalnu ekonomiju relativno skroman, iako statistički

značajan s obzirom na detektirani pozitivan utjecaj na inflaciju kao i utjecaj na BDP i investicije. Evidentno je da u analiziranom periodu cijene nafte nisu predstavljale ograničavajući faktor rasta hrvatske ekonomije što se donekle može zahvaliti i niskom udjelu energije u proizvodnoj strukturi. Uzroci rasta cijena nafte u prevladavajućem dijelu analiziranog perioda imali su uporište u snažnom globalnom gospodarskom rastu koji je potencirao rast potražnje za naftom i njene cijene. Pozitivni gospodarski trendovi hrvatskog gospodarstva od početka trećeg milenija su, zahvaljujući većoj osjetljivosti potražnje za naftom na promjene dohotka negoli na promjene njene cijene, omogućili amortizaciju negativnih efekata rasta cijena nafte.

S obzirom na postojanje niza istraživanja koja ukazuju na konstantne promjene prirode, jačine i smjera odnosa između cijena nafte i pojedinih makroekonomskih pokazatelja, nužno je navedene međuodnose kontinuirano pratiti, analizirati, komparirati i preispitivati. Visoka uvozna ovisnost hrvatskog gospodarstva o nafti naglašava prijeteći karakter naftnih cjenovnih šokova kao i važnost poznavanja mehanizama kojima se s istima možemo adekvatno nositi.

Reduciranje potrošnje nafte svakako je jedna od najzahvalnijih opcija koja vodi smanjenju utjecaja naftnih šokova na gospodarstvo, ali je ujedno i veliki izazov. Smanjenje potrošnje nafte ovisi pri tom o raspoloživim energetskim alternativama kao i ulaganju značajnijih napora ka očuvanju i učinkovitoj potrošnji energije. S jedne se strane suočavamo s nedostatnim, ili bolje reći ograničenim, količinama energije, a s druge strane, ista se neučinkovito koristi. Što je tržište energije konkurentnije i likvidnije i što su brojniji izvori energije (kao i njeni dobavljači), time je i manja izloženost nestabilnostima asociranim s naftnim šokovima. Uloga institucionalnih faktora u diverzifikaciji energetskog portfelja kao i poticanju energetske učinkovitosti (i smanjenju energetske intenzivnosti) pri tom je ključna.

Unatoč naporima nositelja monetarne i fiskalne politike u stabiliziranju makroekonomske situacije, nužni su dodatni napori kako bi se poboljšalo i optimiziralo upravljanje cjelokupnim gospodarstvom. Rizici povezani uz promjene (primarno rast) cijena nafte mogu i moraju biti obuhvaćeni cjelovitom nacionalnom energetskom politikom koja je usmjerena na diverzifikaciju dobavnih pravaca energije (nafte), upravljanje strateškim zalihama nafte, energetsku učinkovitost uporabe nafte i naftnih derivata, kao i uporabu obnovljivih izvora energije.

Najveći izazov je pri tom potrošnja nafte u transportu, koja i globalno čini dvije trećine ukupne potrošnje nafte. Unatoč značajnim tehnološkim naprecima u sferi alternativnih pogonskih goriva u transportu (električni automobili, hibridi i sl.) trenutno dostupna rješenja, zahvaljujući još uvijek relativnoj cjenovnoj nepristupačnosti širim slojevima potrošnje, čine tek zanemariv udio u ukupnoj potrošnji energije u prometu. Ne može se zanemariti ni činjenica da nafta (i njeni derivati), kao još uvijek ključni svjetski energent, podrazumijeva i raširenu infrastrukturu (tankeri, naftovodi, benzinske postaje i sl.) koja još uvijek podržava njeno korištenje, posebice u cestovnom prometu, a na čiju su izgradnju potrošeni i još uvijek se troše bilijuni dolara (čak i kada se isključe troškovi ekstrakcije nafte). U takvim je uvjetima očekivani stupanj i brzina supstitucije nafte alternativnim izvorima energije, koji traže vlastite prilagodbe energetske infrastrukture, čak i uz pretpostavku njihove cjenovne prihvatljivosti i usporedive energetske učinkovitosti, izuzetno nizak. Ne smije se zaboraviti ni silna količina transportnih sredstava u prometu koja ovisi o naftnim derivatima kao pogonskom gorivu (motocikli, automobili, autobusi, kamioni, zrakoplovi, brodovi itd.). Povrh svega navedenog, valja navesti i preferencije kupaca koji još uvijek, u mnogočemu, s određenom skepsom razmatraju potencijalno posjedovanje prometnih sredstava na alternativna pogonska goriva.

Dramatičan rast cijena nafte (naftni šok) posebno je izazovan za nositelje monetarne politike jer isti uzrokuje troškovnu inflaciju, a potencijalno umanjuje i stope realnog rasta. Borba s inflacijskim pritiscima zahtijeva restriktivnu reakciju monetarnih vlasti a, s druge strane, labavija monetarna politika može biti poželjna kako bi se minimizirali potencijalni negativni efekti naftnog šoka na realni rast. Poseban izazov može biti i asimetrična prilagodba cijena naftnih derivata koji sporo reagiraju na pad cijena nafte, na taj način održavajući inflatorne pritiske i sprječavajući bržu pozitivnu reakciju proizvodnog sektora.

Utjecaj cijena nafte na ekonomiju nadalje je direktno vezan uz strukturne ekonomske činitelje kao što su: gospodarska struktura, uvozna ovisnost o nafti, sposobnost smanjenja energetske intenzivnosti, starost proizvodnih kapaciteta (što je veća starost, veća je i energetska intenzivnost) kao i trajnost finalnog proizvoda. Javne politike bi trebale biti usmjerene na supstituciju nafte drugim proizvodnim čimbenicima/energentima te bi trebale uključiti strateške mjere financiranja istraživanja i uporabe alternativnih izvora energije, kao i financiranje energetski učinkovitije opreme i infrastrukture.

Od svih politika, možda je najvažnija politika cijena. Kako je i samo istraživanje pokazalo, fiskalna politika uvelike definira krajnju cijenu derivata nafte kroz poreze i trošarine. Europski i hrvatski građani na ime poreza i trošarina izdvajaju više od polovine krajnje cijene naftnih derivata (za razliku od, primjerice, američkih građana koji za istu namjenu izdvajaju manje od 20% krajnje cijene). S obzirom na izrazito visoku uvoznu ovisnost o nafti i naftnim derivatima koja u Hrvatskoj iznosi 80% (a u EU čak 90%), navedena će se davanja teško smanjivati. Politike bi ipak trebale biti usmjerene na poticanje konkurentnosti na tržištima maloprodaje naftnih derivata kroz olakšavanje ulaska novih konkurenata na tržište čime bi se minimizirala rigidnost cijena derivata prema dolje (cjenovna asimetrija) i onemogućio pritisak na inflaciju kao i proizvodne troškove.

Konačno, pažnju je nužno usmjeriti i na politike strateških obveznih rezervi nafte i naftnih derivata, koje su na inicijativu EU prihvaćene i u Hrvatskoj, s ciljem onemogućavanja značajnih negativnih efekata poremećaja u opskrbi naftom.

LITERATURA

1. ***Aastveit, K., Bjornland, H., Thorsrud, L.*** (2012), What Drives Oil Prices? Emerging Versus Developed Economies, *Norges Bank Working Paper*, Oslo, https://www.norges-bank.no/contentassets/4c0b4b1e90654fd083bd5fae63b77808/norges_bank_working_paper_2012_11.pdf (07/2019)
2. ***Abaidoo, R.*** (2011), Economic growth and energy consumption in an emerging economy: augmented Granger causality approach, *Research in Business and Economics Journal,* Vol. 4, 1-15
3. ***Abdelaziz, M., Chortareas G., Cipollini A.*** (2008), Stock Prices, Exchange Rates, and Oil: Evidence from Middle East Oil-Exporting Countries, Unpublished manuscript, Preuzeto sa: http://www.luc.edu/orgs/meea/volume10/PDFS/Paper%20by%20Abdelaziz&Chortareas&Cipollini.pdf (28.09.2010.)
4. ***Abeysinghe, T***. (2001), Estimation of direct and indirect impacts of oil price on growth, *Economics Letters,* Vol. 73 (2), 147-153
5. ***Acemoglu, D., Aghion, P., Bursztyn, L., Hemous, D.*** (2012), The environment anddirected technical change, *American Economic Review,* Vol. 102, 131-166
6. ***Acurio-Vásconez, V.*** (2015), What if oil is less substitutable? A New-Keynesian Model with oil, Price and Wage Stickiness including Capital Accumulation, *Documents de Travail du Centre d'Economie de la Sorbonne*, Preuzeto sa: http://mse.univ-paris1.fr/pub/mse/CES2015/15041.pdf (application/pdf) (10/2019)
7. ***Acurio-Vásconez, V.*** (2015b), Oil and Unemployment ina a New-Keynesian Model, *Documents de Travail du Centre d'Economie de la Sorbonne*, Preuzeto sa: https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=1&ved=2ahUKEwi5_aa2rrrnAhXtAxAIHZXRDLIQFjAAegQIAhAB&url=https%3A%2F%2Fwww.iaee.org%2Fen%2Fpublications%2Fproceedingsabstractpdf.aspx%3Fid%3D12227&usg=AOvVaw2fANdvBZEfzg8JdiPSjG99 (10/2019)
8. ***Adelman, M.A***. (2002), World oil production & prices 1947-2000, *The Quarterly Review of Economics and Finance,* Vol. 42 (2), 169-191
9. ***Adewuyi, A.O., Awodumi, O.B.*** (2017), Renewable and non-renewable energy-growth-emissions linkages: Review of emerging trends with policy implications, *Renewable and Sustainable Energy Reviews*, Vol. 69, 275-291
10. ***Aghion, P., Howitt, P.*** (1992), A Model of Growth through Creative Destruction, *Econometrica*, Vol. 60 (2), 323-351
11. ***Aghion, P., Howitt, P.*** (1998), *Endogenous Growth Theory*, MIT Press, Cambridge, MA.
12. ***Ågren, M.*** (2006), Does Oil Price Uncertainity Transmit to Stock Markets?, Uppsala Iniversitet, Department of Economics, *Working Paper 2006:23* Preuzeto sa: http://www.nek.uu.se/Pdf/wp2006_23.pdf (07.01.2010.)
13. ***Ahmad, F.*** (2013), The Effect of Oil Prices on Unemployment: Evidence from Pakistan, *Business and Economics Research Journal*, Vol 4., No. 1, 43-57
14. ***Akaike, H.*** (1974), A new look at the statistical model identification, *IEEE Transactions on Automatic Control,* Vol. 19 (6), 716–723
15. ***Al Faris, A***. (1991), The determinants of crude oil price adjustment in the world petroleum market. *OPEC Review* 15.
16. ***Al-Abri, A.*** (2007), Oil-Price Shocks and Macroeconomic Adjustments: Does the Exchange Rate Regime Matter? Preuzeto sa SSRN: http://ssrn.com/abstract=978363 (15.01.2010.)

17. ***Alam, M.S.*** (2006), Economic Growth with Energy, *MPRA Paper 1260*, University Library of Munich, Germany

18. ***Al-Gudhea, S., Kenc, T., Dibooglu, S.*** (2007), Do retail gasoline prices rise more readily than they fall? A threshold cointegration approach, *Journal of Economics and Business,* Vol. 59, 560-574

19. ***Alhajji, A., Huettner D.*** (2000), The target revenue model and the world oil market: Empirical evidence from 1971 to 1994. *The Energy Journal*, Vol. 21(2), 121–144

20. ***Alkhathlana, K., Gately, K. D., Javid, M.*** (2014), *Analysis of Saudi Arabia's behavior within OPEC and the world oil market,* Vol. 64, 209-225

21. ***Al-Qahtani, A., Balistreri E., Dahl C.*** (2008), Literature Review on Oil Market Modeling and OPEC's Behavior, Preuzeto sa: http://www.cepe.ethz.ch/education/EnergyPolicy/LitReviewOPEC.pdf, (08/2009.)

22. ***Alquist. R., Gervais, O.*** (2013), The Role of Financial Speculation in Driving the Price of Crude Oil, *The Energy Journal*, Vol. 34(3), 35-54

23. ***Alquist. R., Kilian, L.*** (2010), What do we learn from the price of crude oil futures? *Journal of Applied Econometrics*, Vol. 25, 539–573

24. ***Alsalman, Z.N., Karaki, M.B.*** (2019), Oil Prices and Personal Consumption Expenditures: Does the Source of the Shock Matter?, *Oxford Bulletin of Economics & Statistics*, Vol. 81(2), 250-270

25. ***Álvarez, L.J. et al.*** (2011), The impact of oil price changes on Spanish and euro area consumer price inflation, *Economic Modelling*, Vol. 28, 422-431

26. ***Amano, R. A., van Norden, S.*** (1998), Oil prices and the rise and fall of U.S. real exchange rate, *Journal of International Money and Finance,* Vol. 17, 299-316

27. ***An, L., Jin, X., Ren, X.*** (2014), Are the macroeconomic effects of oil price shock symmetric?: A Factor-Augmented Vector Autoregressive approach, *Energy Economics*, Vol. 45, 217-228

28. ***Andreopoulos, S.*** (2009), Oil matters: real input prices and U.S. unemployment revisited, *The B.E. Journal of Macroeconomics*, Vol. 9 (1), 1–29

29. ***Antolín-Díaz, J., Rubio-Ramírez, J. F***. (2018), Narrative Sign Restrictions for SVARs, *American Economic Review,* Vol. 108 (10), 2802-2829

30. ***Apergis, N., Miller, S.M.*** (2009), Do structural oil-market shocks affect stock prices? *Energy Economics,* Vol. 31, 569-575

31. ***Apergis, N., Payne, J.E., Menyah, K., Wolde-Rufael, Y.*** (2010), On the causal dynamics between emissions, nuclear energy, renewable energy, and economic growth, *Ecological Economics*, Vol. 69, 2255–2260

32. ***Archanskaïa, E., Creel, J., Hubert, P.*** (2012), The nature of oil shocks and the global economy, *Energy Policy*, Vol. 42, 509-520

33. ***Arnold, R. A.*** (2008), *Economics*, Mason: South-Western Cengage Learning

34. ***Asplund, M., Eriksson, R., Friberg, R.*** (2000), Price adjustments by a gasoline retail chain, *Scandinavian Journal of Economics*, Vol. 102, 101–121

35. ***Asteriou, D., Hall, S.G.*** (2006), *Applied Econometrics: A Modern Approach using Eviews and Microfit,* Palgrave Macmillan, New York, USA

36. ***Atil., A., Lahiani, A., Khuong Nguyen, D.*** (2014), Asymmetric and nonlinear pass-through of crude oil prices to gasoline and natural gas prices, *Energy Policy*, Vol. 65, 567-573

37. ***Atkeson, A., Kehoe, P.J.*** (1999), Models of energy use: putty-putty versus putty-clay, *American Economic Review*, Vol. 89, 1028-1043

38. ***Atkins, F., Tayyebi Jazayeri, S.M.*** (2004), A literature review of demand studies in world oil markets, University of Calgary, Department of Economics Discussion Paper 2004-07

39. ***Awerbuch, S., Sauter, R.*** (2006), Explaining the oil-GDP effect to support renewable deployment, *Energy Policy*, Vol. 31, 2805–2819

40. ***Ayres, R.U., van den Bergh, J.C.J.M.*** (2005), A theory of economic growth with material/energy resources and dematerialization: Interaction of three growth mechanisms, *Ecological Economics*, Vol. 55(1), 96-118

41. ***Ayres, R.U., van den Bergh, J.C.J.M., Lindenberger, D., Warr, B***. (2013). The underestimated contribution of energy to economic growth, *Structural Change and Economic Dynamics*, Vol 27, 79-88

42. ***Ayres, R.U., Warr, B.*** (2005), Accounting for growth: the role of physical work, *Structural Change and Economic Dynamics,* Vol. 16 (2), 181–209

43. ***Ayres, R.U., Warr, B.*** (2009), *The Economic Growth Engine: How Energy and Work Drive Material Prosperity*, Edward Elgar, Cheltenham

44. ***Azeki, R., Jakab, Z., Laxton, D., Matsumoto, A., Nurbekyan, Wang, H., Jiaxiong, Y***. (2017), Oil Prices and the Global Economy, IMF Working Paper No. 17/15

45. AZTN, Agencija za zaštitu tržišnog natjecanja (2018), *Nema pokazatelja koji ukazuju na značajne promjene marži trgovaca nakon liberalizacije*, Preuzeto sa: http://www.aztn.hr/6930/ (08/2018)

46. ***Bachmeier, L.*** (2008), Monetary policy and the transmission of oil shocks, *Journal of Macroeconomics*, Vol. 30 (4), 1738-1755

47. ***Bachmeier, L.J., Grif n, J.M.*** (2003), New evidence on asymmetric gasoline price responses, *Review of Economics and Statistics,* Vol. 85, 772–776

48. ***Bachmeier, L.J., Keen, B.D.*** (2017), Modeling the Asymmetric Effects of Oil PriceShocks, *24th International Conference Computing in Economics and Finance*, Università Cattolica del Sacro Cuore, Milan, Italy, June 19 - 21, 2018

49. ***Backus, D., Crucini, M.*** (2000), Oil prices and the terms of trade, *Journal of International Economics*, Vol. 50 (1), 185-213

50. ***Bacon, R.*** (1991), Modelling the price of oil, *Oxford Review of Economic Policy*, Vol. 7, 17-34

51. ***Bahovec, V., Erjavec N.*** (2009), *Uvod u ekonometrijsku analizu*, Element d.o.o., I izdanje

52. ***Balabanoff, S.*** (1995), Oil futures prices and stock management: a cointegration analysis, *Energy Economics*, Vol. 17 (3), 205–210

53. ***Balaguer, J., Ripollés, J.*** (2012), Testing for price response asymmetries in the Spanish fuel market. New evidence from daily dana, *Energy Economics*, Vol. 34 (6), 2066-2071

54. ***Balassa, B.*** (1964), The Purchasing Power Parity Doctrine: A Reappraisal, *Journal of Political Economy*, Vol. 72, 584-596

55. ***Balke, N. S., Brown, S. P. A, Yücel, M. K.*** (2002), Oil Price Shocks and the U.S. Economy. Where does the Assymetry Originate, *The Energy Journal,* Vol. 23 (3), 27-52

56. ***Bamberger, R.L., Pirog, R.*** (2008), The disparity between retail gasoline and diesel fuel prices, Congressional Research Service: Report RL34431: Washington DC

57. ***Barić, V., Čavrak, V.*** (2005), *Osnove hrvatskog gospodarstva*, materijali za izučavanje, Sveučilište u Zagrebu, Ekonomski fakultet i Mikrorad d.o.o., Zagreb

58. ***Barnabé, W.*** (2018), Labour productivity growth and energy in Europe: A production-frontier approach, *Energy*, Vol. 152, 129-143

59. ***Barro, R.J., Sala-i-Martin, X.*** (1995), *Economic Growth*, 1st ed. NV, McGraw Hill

60. ***Barro, R.J., Sala-i-Martin, X.*** (2003), *Economic Growth*, 2nd ed. MIT Press, Cambridge, MA.

61. ***Barsky, R. B., Kilian L.*** (2004), Oil and the Macroeconomy Since the 1970s, *Journal of Economic Perspectives*, Vol. 18, 115-134

62. ***Baumeister, C., Hamilton, J.D.*** (2019), Structural Interpretation of Vector Autoregressions with Incomplete Identification: Revisiting the Role of Oil Supply and Demand Shocks, *American Economic Review,* Vol. 109 (5), 1873-1910

63. ***Baumeister, C., Kilian, L***. (2015), Understanding the Decline in the Price of Oil since June 2014, *SSRN Electronic Journal,* Preuzeto sa: https://www.researchgate.net/publication/ 277329985_ Understanding_the_Decline_in_the_Price_of_Oil_Since_June_2014 (08/2019)

64. ***Baumeister, C., Kilian, L***. (2016), Forty Years of Oil Price Fluctuations: Why the Price of Oil May Still Surprise Us, *Journal of Economic Perspectives*, Vol. 30 (1), 139-160

65. ***Baumeister, C., Peersman, G.*** (2013), The role of time-varying price elasticities in accounting for volatility changes in the crude oil market, *Journal of Applied Econometrics*, Vol. 28, 1087–1109

66. ***Baumeister, C., Peersman, G., Van Robays, I.*** (2009), The Economic Consequences of Oil Shocks: Differences Across Countries and Time, Univeriteit Gent Working Paper 2009/630, D/2009/7012/81, Preuzeto sa: http://wps-feb.ugent.be/Papers/wp_09_630.pdf (05/2013)

67. ***Beaudreau, B.C.*** (2005), Engineering and economic growth, *Structural Change and Economic Dynamics*, Vol. 16 (2), 211–220

68. ***Bebek, S., Santini, G.*** (2008), Hrvatska inflacija - jucer danas sutra, *Economics*, Vol. 15 (2), 219-261

69. ***Becker, G., Murphy, K., Tamura, R.*** (1990), Human Capital, Fertility, and Economic Growth, *Journal of Political Economy*, Vol. 98 (5), 12-37

70. ***Bekiros, S. D., Diks, C.G.H.*** (2008), The relationship between crude oil spot and futures prices: Cointegration, linear and nonlinear causality, *Energy Economics*, Vol. 30 (5), 2673-2685

71. ***Benassy-Quere, A., Mignon V., Penot A.*** (2007), China and the relationship between the oil price and the dollar, *Energy Policy,* Vol. 35, 5795-5805

72. ***Benazić, M.*** (2009), *Monetarni transmisijski mehanizam u Republici Hrvatskoj*, doktorska disertacija, Sveučilište u Zagrebu, Ekonomski fakultet, Zagreb

73. ***Berk, Ý., Yetkiner I. H.*** (2013), Energy Prices and Economic Growth: Theory and Evidence in the Long Run, *Working Papers* 1303, *Izmir University of Economics*

74. ***Bermingham, C., O'Brien, D.*** (2011), Testing asymmetric pricing behaviour in Irish and UK petrol and diesel markets, *Energy Journal,* Vol. 32, 1–26

75. ***Bernanke, B.S.*** (1983), Irreversibility, Uncertainty and Cyclical Investment, *Quarterly Journal of Economics*, 98 (1), 85-106

76. ***Bernanke, B.S., Gertler, M., Watson, M.*** (1997), Systematic Monetary Policy and the Effects of Oil Price Shocks, *Brookings Papers on Economic Activity*, Vol. (1), 91-157

77. ***Berndt, E.R., Wood, D.O.*** (1975), Technology, Prices, and the Derived Demand for Energy, *Review of Economics and Statistics*, Vol. 57, 259-268

78. ***Berndt, E.R., Wood, D.O.*** (1979), Engineering and Econometric Interpretations of Energy-Capital Complementarity, *American Economic Review*, Vol. 69, 342-354

79. ***Berument, H., Ceylan, N.B***. (2010), The Impact of Oil Price Shocks on The Economic Growth of The Selected MENA Countries, *The Energy Journal*, Vol. 31(1), 149-176

80. ***Bettendorf, L., Van der Geest, S.A., Kuper, G.*** (2009), Do daily retail gasoline prices adjust asymmetrically? *Journal of Applied Statistics,* Vol. 36, 385–397

81. ***Bettendorf, L., Van der Geest, S.A., Varkevisser, M.*** (2003), Price asymmetry in the Dutch retail gasoline market, *Energy Economics*, Vol. 25, 669–689

82. ***Bićanić, I., Babić, Z.*** (2008), Survey of the Croatian Labour Market, *Labour Market Characteristics in Selected Economies*, Boršič, D. & Kavlker, A. (ur.) Maribor: Schwarz, Ltd., 51-69

83. ***Bilgin, M.H., Gozgor, G., Karabulut, G.*** (2015), The Impact of World Energy Price Volatility on Aggregate Economic Activity in Developing Asian Economies, *The Singapore Economic Review*, World Scientific Publishing Co. Pte. Ltd., Vol. 60 (1), 1-20

84. ***Binswanger, M.*** (2001), Technological progress and sustainable development: What about the rebound effect?, *Ecological Economics,* Vol. 36(1), 119-132

85. ***Blanchard, O.*** (2005), *Makroekonomija*, III. Izdanje, Mate d.o.o., Zagreb

86. ***Blanchard, O., Gali J.*** (2007), The Macroeconomic Effects Of Oil Shocks: Why Are The 2000s So Different From The 1970s, *NBER Working Paper* 13368, 1-78

87. ***Bloch, H., Dockery, A.M., Sapsford, D.*** (2006), Commodity prices and the dynamics of inflation in commodity-exporting nations: evidence from Australia and Canada, *Economic Record*, Vol. 82, 97-109

88. ***Bloom, N., Bond, S., Van Reenen, J.,*** (2007) Uncertainty and investment dynamics, *Review of Economic Studies*, Vol. 74, 391-415

89. ***Bodenstein, M., Guerrieri, L.*** (2011), Oil efficiency, demand, and prices: a tale of ups and downs, Board of Governors of the Federal Reserve System (U.S.), *International Finance Discussion Papers* 1031

90. ***Bodenstein, M., Guerrieri, L., Kilian L.*** (2012), Monetary Policy Responses to Oil Price Fluctuations, *IMF Economic Review*, Palgrave Macmillan; International Monetary Fund, Vol. 60(4), 470-504

91. ***Bohi, D.R.*** (1991), On the Macroeconomic Effects of Energy Price Shocks*, Resources and Energy*, Vol. 13, 145-162

92. ***Bokan, N., Dossche, M., Rossi, L.*** (2018), Oil prices, the terms of trade and private consumption, *Economic Bulletin Boxes, European Central Bank*, Vol. 6.

93. ***Bokan, N., Grgurić, L., Krznar, I., Lang, M.*** (2010), Utjecaj financijske krize i reakcija monetarne politike u Hrvatskoj, *HNB istraživanja,* Preuzeto sa: https://www.hnb.hr/documents/20182/121339/i-025.pdf/0cedb8e9-c523-4d60-8a1a-9a80daa56a2f, (08/2018)

94. ***Borenstein, S. A., Cameron, C., Gilbert, R.*** (1997), Reducing U.S. Vulnerability to World Oil Supply Disruptions, *Federal Reserve Bank of Dallas Economic Review*, 1-13

95. ***Borenstein, S., Shepard, A.*** (1996), Dynamic pricing in retail gasoline markets, *Rand Journal of Economics,* Vol. 27, 429–451

96. ***Borozan, Dj.*** (2011), Granger causality and innovation accounting analysis of the monetary transmission mechanism in Croatia, *Post-Communist Economies*, Vol. 23(4), 517-537

97. ***Borozan, Dj.*** (2013), Exploring the relationship between energy consumption and GDP: Evidence from Croatia", *Energy Policy*, Vol. 59, 373-381

98. ***Borozan, Dj., Sonora, R.J.*** (2014), Monetary policy in a small open transition economy with a managed exchange rate: Evidence from Croatia, Preuzeto sa: https://www.researchgate.net/publication/265377443_Monetary_Policy_in_a_Small_Open_Transition_Economy_with_a_Managed_Exchange_Rate_Evidence_from_Croatia, (03/2017)

99. ***Botrić, V.*** (2009), Unemployed and long-term unemployed in Croatia: evidence from Labour Force Survey, *Revija za socijalnu politiku*, Vol. 16 (1), 25-44

100. ***Botrić, V., Cota, B.*** (2006), Sources of Inflation in Transition Economy: The Case of Croatia, *Ekonomski pregled,* Vol. 57 (12), 835-855

101. ***Bououiyour, J., Selmi, R., Ozturk, I.*** (2014), The Nexus between Electricity Consumption and Economic Growth: New Insights from Meta-Analysis, *International Journal of Energy Economics and Policy*, Vol. 4(4), 621-635

102. ***BP*** (2010), British Petroleum, *BP Statistical Review of World Energy*, British Petroleum, Preuzeto sa: http://www.bp.com/liveassets/bp_internet/globalbp/globalbp_uk_english/reports_and_publications/statistical_energy_review_2008/STAGING/local_assets/2010_downloads/primary_energy_section_2010.pdf (08/2010)

103. ***BP*** (2011), British Petroleum, *BP Energy Outlook 2030,* Preuzeto sa: https://www.bp.com/content/dam/bp/business-sites/en/global/corporate/pdfs/energy-economics/energy-outlook/bp-energy-outlook-2011.pdf (08/2019)

104. ***BP*** (2015), British Petroleum, *BP Statistical Review 2015*, Brent prices, for world production changes (EIA, Monthly Energy Review, 2016, Table 11.1b).

105. ***BP*** (2016), British Petroleum, *BP Statistical Review of World Energy*, Preuzeto sa: https://www.bp.com/content/dam/bp/pdf/energy-economics/statistical-review-2016/bp-statistical-review- of-world-energy-2016-full-report.pdf (06/2018)

106. ***BP*** (2016), British Petroleum, *BP Statistical Review of World Energy 2016 - data workbook: Oil production - barrels,* Preuzeto sa: http://www.bp.com/en/global/corporate/energyeconomics/statistical-review-of-world-energy.html (07/2016)

107. ***Bredin, D., Elder, J., Fountas, S.*** (2010), The effects of uncertainty about oilprices in G-7, Geary Institute, *University College Dublin Working Papers*, Paper No. 2010–01

108. ***Breshnan, T., Ramey, V.*** (1993), Segment Shifts and Capacity Utilization in the U.S. Automobile Industry, *American Economic Review Papers and Proceedings*, Vol. 83, 213-218

109. ***Bretschger, L., Lechthale,r F., Rausch, S., Zhang, L.*** (2017), Knowledge diffusion,endogenous growth, and the costs of global climate policy, *European Economic Review*, Vol. 93, 47-72

110. ***Bretschger, L., Schaefer, A.*** (2017), Dirty history versus clean expectations: Can energy policies provide momentum for growth?, *European Economic Review*, Vol. 99, 170-190

111. ***Brooks, C.*** (2008), *Introductory Econometrics for Finance*, Cambridge, Cambridge University Press

112. ***Brown, S.P.A., Yücel M.K.*** (1999), Oil Prices and U.S. Aggregate Economic Activity: A Question of Neutrality, *Economic and Financial Review*, Federal Reserve Bank of Dallas, Second Quarter, 16-23

113. ***Brown, S.P.A., Yücel, M.K., Thompson, J.*** (2003), *Business Cycles: The Role of Energy Prices*, Research Department Working Paper 0304, Federal Reserve Bank of Dallas, Preuzeto sa: https://core.ac.uk/download/pdf/7359279.pdf (08/2010)

114. ***Bukovšak, M., Lukinić Čardić, G., Ranilović, G.*** (2017), Struktura tokova kapitala i devizni tečaj: primjer Hrvatske, *HNB, Istraživanja* I-49, Preuzeto sa: https://www.hnb.hr/documents/20182/2030174/i-049.pdf/3031e76b-739f-48fb-9cfe-98109b224b7b (09/2018)

115. ***Burbidge, J., Harisson, A.*** (1984), Testing for the Effects of Oil Price Rises Using Vector Autoregression, *International Economic Review*, Vol. 25, 459-484

116. ***Butigan, R.*** (2007), Konkurentsko okružje - moderator razvoja maloprodaje derivata nafte 2007., *magistarski rad,* Ekonomski fakultet, Zagreb

117. ***Calel, R., Dechezlepretre, A.*** (2016), Environmental policy and directed technolog-ical change: evidence from the European carbon market, *Review of Economics and Statistics*, Vol. 98, 173-191

118. ***Calvo, G***. (1979), Quasi-Walrasian Theories of Unemployment, *American Economic Review*, Vol. 69 (2), 102-107

119. ***Calvo, G.A., Leiderman, L., Reinhart, C.M.*** (1993), Capital Inflows and Real Exchange Rate Appreciation in Latin America: The Role of External Factors, *IMF Staff Papers*, Vol. 40 (1), 108 – 151

120. ***Campbell, J.Y., Mankiw, G.*** (1989), Consumption, Income, and Interest Rates: Reinterpreting the Time Series Evidence, *NBER Working Paper* No. 2436.

121. ***Cantore, N., Antimiani, A., Anciaes, P.R.*** (2012), Energy Price Shocks: Sweet and Sour Consequences for Developing Countries, Overseas Developing Institute, Working Paper 355, London

122. ***Caporale, M., Pittis, N.*** (1997), Causality and forecasting in incomplete systems, *Journal of Forecasting,* Vol. 16, 425-437

123. ***Carmona, M., Congregado, E., Feria, J., Iglesias, J.*** (2017), The energy-growth nexus reconsidered: Persistence and causality, *Renewable and Sustainable Energy Reviews*, Vol. 71, 342-347

124. ***Carollo, S.*** (2012), *Understanding Oil Prices: A Guide to What Drives the Price of Oil in Today's Markets*, Wiley Finance, Wiley and Sons Inc., 1. izdanje

125. ***Carruth, A., Dickerson, A., Henley, A.*** (2000), What Do We Know About Investment Under Uncertainty?, *Journal of Economic Surveys*, Vol. 14(2), 119 - 154

126. ***Carruth, A.A., Hooker M.A., Oswald, A.J.*** (1998), Unemployment equilibria and input prices: Theory and evidence from the United States, *Review of Economics and Statistics*, Vol. 80, 621–628

127. ***Cashin, P., Liang, H., McDermott, C.J.*** (1999), How persistent are shocks to world commodity prices?*, International Monetary Fund Working Paper* No. 99/80.

128. ***Cashin, P., McDermott, C.J.*** (2002), The Long Run Behaviour of Commodity Pricesa: Small Trends and Big Variability, International Monetary Fund, IMF Staff Papers, Vol. 49 (2), 175-199

129. ***Cashin, P., Mohaddes, K., Raissi, M., Raissi, M.*** (2014), The Differential Effects of Oil Demand and Supply Shocks on the Global Economy, *Energy Economics*, Vol. 44, 113-134

130. ***Cavallo, A., Ribba, A***. (2018), Measuring the effects of oil price and Euro-area shocks on CEECs business cycles, *Journal of Policy Modeling,* Vol. 40 (1), 74-96

131. ***Cerić, E.*** (2012), *Nafta - procesi i proizvodi.* Sarajevo: IBC d.o.o.

132. ***Cerovac, S.*** (2005), Novi kompozitni indikatori za hrvatsko gospodarstvo: prilog razvoju domaćeg sustava cikličkih indikatora, *Istraživanja* br. 16, Hrvatska narodna banka

133. ***Chang, Y., Jha, K., Fernández, K., Jam'an, F.*** (2011), Oil Price Fluctuations and Macroeconomic Performances in Asian and Oceanic Economies, Preuzeto sa: http://www.usaee.org/usaee2011 /submissions/OnlineProceedings/Chang%20et%20al_Full%20Paper.pdf (11/2019)

134. ***Chang, Y., Wong, J.F.*** (2003), Oil price fluctuations and Singapore economy, *Energy Policy*, Vol. 31 (11), 1151-1165

135. ***Chen, L-H., Finney, M., Lai, K.S.*** (2005), A threshold cointegration analysis of asymmetric price transmission from crude oil to gasoline prices, *Economics Letters,* Vol. 89, 233–239

136. ***Chen, M., Wen, Y.*** (2011), Oil price shocks and inflation risk. Economic Synopses, *Short essays and reports on theeconomic issues of the day, No 19., Federal Resreve Bank of St. Louis*

137. ***Chen, P.Y., Chen, S.T., Chen, C.C.*** (2012), Energy consumption and economic growth - new evidence from meta-analysis, *Energy Policy*, Vol. 44, 245-255

138. ***Chen, S.S.*** (2009), Oil price pass-through into inflation*, Energy economics*, Vol. 31, 126-133

139. ***Chevillon, G., Rifflart C.,*** (2009), Physical market determinants of the price of crude oil and the market premium*, Energy Economics,* Vol. 31, 537–549

140. ***Chirinko, R.S.*** (1993), Business Fixed Investment Spending: Modeling Strategies, Empirical Results, and Policy Implications, *Journal of Economic Literature*, Vol. 31 (4), 1875-1911

141. ***Choi, S., Furceri, D., Loungani, P., Mishra, S., Poplawski-Ribeiro, M***. (2018), Oil Prices and Inflation Dynamics: Evidence from Advanced and Developing Economies, *Joutnal of Inetrnational Money and Finace,* Vol. 82, 71-96

142. ***Chow, G., Lin, A.*** (1971), Best Linear Unbiased Interpolation, Distribution, and Extrapolation of Time Series by Related Series. *The Review of Economics and Statistics*, Vol. 53, 372-375

143. ***Ciner, C.*** (2001), Energy Shocks and Financial Markets: Nonlinear Linkages, *Studies in Nonlinear Dynamics and Econometrics*, Vol. 5(3), 203-212

144. ***Clemens, M.P., Hendry, D.F.*** (1995), Macro-economic forecasting and modelling, *Economic Journal,* Vol. 105, 1001-1013

145. ***Cleveland, C., Costanza, R.*** (2008), Net energy analysis, chapter in *Encyclopedia of Earth*, Ed. Cleveland, C., Environmental Information Coalition, National Council for Science and the Environment, Washington, DC.

146. ***Cleveland, C.J., Costanza, R., Hall, C.A.S., Kaufmann, R.*** (1984), Energy and the U.S. economy: a biophysical perspective, *Science*, Vol. 225, 890–897

147. ***Cleveland, C.J., Kaufmann, R.K., Stern, D.I***. (2000), Aggregation and the role of energy in the economy, *Ecological Economics,* Vol. 32, 301–317

148. ***Cnossen, S.*** (1990), *The Case For Selective Taxes On Goods And Services In Developing Countries*. In: R. M. Bird and O. Oldman, eds. Taxation In Developing Countries. 4th ed. Baltimore; London: The John Hopkins University Press.

149. ***Cologni, A., Manera, M.*** (2008), Oil prices, inflation and interest rates in a structural cointegrated VAR model for the G-7 countries, *Energy Economics*, Vol. 30 (3), 856-888

150. ***Cook, S., Fosten, J. (2019),*** Replicating rockets and feathers*, Energy Economics,* Vol. 82, 139-151

151. ***Cooper, J.*** (2003), Price elasticity of demand for crude oil: estimates for 23 countries*, OPEC Review,* Vol. 27(1), 1-8

152. ***Corden, W. M.*** (1994), *Economic Policy, Exchange Rates and the International System*, Oxford University Press

153. ***Costa-Campi M.T., Garca-Quevedo J., Trujillo-Baute, E.*** (2018), Electricity regulation and economic growth, *Energy Policy,* Vol. 113, 232-238

154. ***Cota, B.*** (2007), Pregled empirijskih istraživanja utjecaja cijena energenata na ukupnu privrednu aktivnost*, Ekonomska istraživanja*, Vol. 20 (1), 109-118

155. ***Cottrel, F.*** (1955), Ener*gy and Society: the relation between energy, social change and economic development*, McGraw Hill Book Company Inc. New York

156. ***Crnković Pozaić, S.*** (2002), Nezaposleni koji rade: radnici i poduzetnici iz sjene*, Financijska teorija i praksa,* Vol. 26 (1), 301-316

157. ***Crompton, P., Wu, Y***. (2005), Energy consumption in China: past trends and future directions, *Energy Economics,* Vol. 27 (1), 195-208

158. ***Cross, J., Nguyen, B.H***. (2017), The relationship between global oil price shocks and China's output: A time-varying analysis, *Energy Economics,* Vol. 62, 79-91

159. ***Cuestas, J.C., Gil-Alana, L.A.*** (2018), Oil price shocks and unemployment in Central and Eastern Europe, *Economic Systems*, Vol. 42, 164-173

160. ***Cunado, J., Jo, S., Perez de Gracia, F.*** (2015), Macroeconomic impacts of oil price shocks in Asian economies, *Energy Policy*, Vol. 86, 867-879

161. ***Cunado, J., Perez de Gracia, F.*** (2003), Do oil price shocks matter? Evidence for some European countries, *Energy Economics,* Vol. 25(2), 137-154

162. ***Cunado, J., Perez de Gracia, F.*** (2005), Oil Prices, Economic Activity and Inflation: Evidence for Some Asian Countries, *The Quarterly Review of Economics and Finance*, Vol. 45 (1), 65-83

163. ***CVH, Centar za vozila Hrvatske*** (2018), Tehnički regled, Statistika, Pregled starosti vozila prema vrstama vozila, Preuzeto sa: https://www.cvh.hr/media/2750/s01pregled_starosti_vozila_prema vv_rtp_2017.pdf, (08/2018)

164. ***Čavrak, V., Gelo, T., Pripužić, D***. (2006), Politika cijena u energetskom sektoru i utjecaj cijena energenata na gospodarski razvoj Republike Hrvatske, *Zbornik Ekonomskog fakulteta u Zagrebu,* Vol.4 (1), 45-68

165. ***Dagum, E.B., Cholette, P. A.*** (2006), *Benchmarking, Temporal Distribution and Reconciliation Methods for Time Series*, Springer, New York.

166. ***Dahl, C.A.*** (2008), *Međunarodna tržišta energije cijene, politike i profiti*, Kigen d.o.o., Zagreb

167. ***Daniel, B.C.*** (1997), International Interdependence of National Growth Rates; A Structural Trend Analysis, *Journal of Monetary Economics*, Vol. 40, 73-96

168. ***Darby, M.R.*** (1982), The Price of Oil and World Inflation and Recession, *American Economic Review*, Vol. 72, 738-751

169. ***Dasgupta, P., Heal, G.*** (1974), The Optimal Depletion of Exhaustible Resources, *Review of Economic Studies*, Vol. 41 (5), 3-28

170. ***Davis, S.J.*** (1987a), Allocative Disturbances and Specific Capital in Real Business Cycle Theories, *American Economic Review Papers and Proceedigs*, Vol. 77, 326-332

171. ***Davis, S.J.*** (1987b), Fluctuations in the pace of labour reallocation, In: Brunner, K., Meltzer, A.H., ed., *Empirical Studies of Velocity, Real Exchange rates, Unemployment and Productivity*, Vol. 27, Carnegie-Rochster Conference Series on Public Polic, 335-402

172. ***Davis, S.J., Haltiwanger, J.*** (2001), Sectoral job creation and destruction responses to oil price changes, *Journal of Monetary Economics*, Vol. 48, 465-512

173. ***De Michelis***

174. ***Dees, S., Karadeloglou, P., Kaufmann, R.K., Sanchez, M.*** (2007), Modelling the world oil market: Assessment of a quarterly econometric model, *Energy Policy,* Vol. 35(1), 178–191

175. ***Deltas, G.*** (2008), Retail gasoline price dynamics and local market power, *Journal of Industrial Economics,* Vol. 56, 613-628

176. ***Denison, E.*** (1979), *Accounting For Slower Economic Growth*, The Brookings Institution, Washington, D.C.

177. ***Denona Bogović, N.*** (2002), Dugoročna obilježja osobne potrošnje u Republici Hrvatskoj, *Ekonomski pregled*, Vol. 53 (7-8), 622-639

178. ***Dhawan, R., Jeske, K.*** (2008), Energy price shocks and the macroeconomy: the role of consumer durables, *Journal of Money Credit and Banking*, Vol. 40, 1357–1377

179. ***Dhyne, E. et al.*** (2006), Price changes in the euro area and the United States: some facts from individual consumer price dana, *The Journal of Economic Perspectives*, Vol. 20 (2), 171-192

180. ***Dickey, D.A., Fuller, W.A.*** (1979), Distribution of the Estimators for Autoregressive Time Series With a Unit Root, *Journal of the American Statistical Association,* Vol. 74, 427-431

181. ***Dixit, A.K., Pindyk, R.S.*** (1994), *Investment under uncertainity*, Princeton University Press, Prnceton, New Jeresy

182. ***Doğrul, H.G., Soytas, U.*** (2010), Relationship between oil prices, interest rate and unemployment: evidence from an emerging market, *Energy Economics*, Vol. 32, 1523-1528

183. ***Doležal, V.*** (2011), Efficiency of the Monetary Transmission Mechanism in Croatia, *Privredna kretanja i ekonomska politika*, Vol. 21 (128), 27-55

184. ***Donayre, L., Wilmot, N.A.*** *(*2016), The asymmetric effects of oil price shocks on the Canadian economy, *International Journal of Energy Economics and Policy,* Vol. 6(2), 167-182

185. ***Dornbusch, R., Fischer, S.*** (1980), Exchange rates and current account, *American Economic Review,* Vol. 70, 960-971

186. ***Doroodian, K., Boyd, R.*** (2003), The linkage between oil price shocks and economic growth with inflation in the presence of technological advances: a CGE model, *Energy Policy,* Vol. 31, 989-1006

187. ***Driver, C., Yip, P., Dahkil, N.*** (1996), Large company capital formation and effects of market share turbulence: micro-data evidence from the PIMS database, *Applied Economics*, Vol. 28, 641-651

188. ***Druant, M., Fabiani, S., Kedzi, G., Lamo, A., Martins, F., Sabbatini, R.*** (2012), Firms' price and wage adjustment in Europe: survey evidence on nominal stickiness, *Labour Economics*, Vol. 19 (5), 772-782

189. ***Družić, I.*** (1998), Tržišno restrukturiranje i privatizacija hrvatskog gospodarstva, *Hrvatsko gospodarstvo*, Barić, V. (ur.), Zagreb, Politička kultura, 110-134

190. ***Družić, I.*** (2004), *Resursi i tržišta hrvatskog gospodarstva,* Zagreb, Politička kultura

191. ***Družić, I.*** (2005), *Ekonomska politika i poduzetništvo*, HAZU, HITA, Zagreb.

192. ***Du, K., Lin, B.*** (2017), International comparison of total-factor energy productiv-ity growth: A parametric Malmquist index approach, *Energy*, Vol. 118, 481-488

193. ***Dvir, E., Rogoff, K.*** (2010), Three Epochs of Oil, *NBER Working Papers* from National Bureau of Economic Research, No 14927

194. ***Dybczak, K., Vonka, D., Van der Windt, N.*** (2008), The Effect of Oil Price Shocks on the Czech Economy, *Czech National Bank Working Paper Series*, 5:40.

195. ***DZS*** (1999), Državni zavod za statistiku, *Cijene i troškovi života u 1998.*, Statistička izvješća, 1096/1999, Zagreb, 1999., str. 9.

196. ***DZS*** (2009), Državni zavod za statistiku, *Eurostat priručnik za izvještaje o kvaliteti Europskog statističkog sustava*, Preuzeto sa: https://www.dzs.hr/Hrv_Eng/Other/Prirucnik%20za%20 izvjestaje %20o%20kvaliteti%20Europskog%20statistickog%20sustava.pdf (05/2015)

197. ***DZS*** (2011), Državni zavod za statistiku, *ESS Smjernice o desezoniranju*, Preuzeto sa: https://www. dzs.hr/Hrv_ Eng/Other/ESS_smjernice.pdf (05/2015)

198. ***DZS*** (2012), Državni zavod za statistiku, *Rezultati ankete o potrošnji kućanstava u 2010*., Preuzeto sa: https://www.dzs.hr /hrv_eng/publication/2011/si-1456.pdf (04/2018)

199. ***DZS*** (2013), Državni zavod za statistiku, *Anketa o radnoj snazi, Metodološke upute*, Preuzeto sa: https://www.dzs.hr/ hrv/publication/metodologije/metod_71.pdf (04/2018)

200. ***DZS*** (2017), Državni zavod za statistiku, *Statistička izvješća, Cijene u 2016*., Preuzeto sa: https://www.dzs.hr/Hrv_Eng/ publication/2017/SI-1608.pdf (03/2018)

201. ***DZS*** (2017a), Državni zavod za statistiku, *Priopćenje 12.1.4., Godišnji bruto domaći proizvod za 2015. (ESA 2010), Tablica 12-01-04-01-h*, Preuzeto sa: https://www.google.com/search?q =BRUTO+DOMA%C4%86I+PROIZVOD+PREMA+RASHODNOJ+METODI+OD+1995.+DO +2015.%2C+stalne+cijene+u+cijenama+prethodne+godine%2C+referentna+godina+2010.%2C+ %28ESA+2010%29&ie=utf-8&oe=utf-8&client=firefox-b-ab (03/2018)

202. ***DZS*** (2018a), Državni zavod za statistiku, *Industrija, Indeks industrijske proizvodnje, Indeks obujma industrijske proizvodnje, ukupno, sezonski i kalendarski prilagođeni indeksi (2010=100),* Preuzeto sa: https://www.dzs.hr/App/PXWeb/PXWebHrv/Selection.aspx?px_path=Industrija

Indeks%20industrijske%20proizvodnje&px_tableid=BS_IN13.px&px_language=hr&px_db=Industrija&rxid=fc9d580f-2229-4982-a72c-cdd3e96307d3 (02/2018)

203. ***DZS*** (2018b), Državni zavod za statistiku, *Bruto domaći proizvod, tromjesečni obračun, stalne cijene, referentna godina 2010*., Preuzeto sa: https://www.dzs.hr/Hrv_Eng/publication/2016/12-01-01_04_2016.htm (02/2018)

204. ***EAMA*** (2018), European Automobile Manufacturer Association, *Statistics*, Preuzeto sa: https:// www.acea.be/ statistics /tag/category/per-capita-registrations (08/2018)

205. ***EC*** (2019), Europska Komisija, Komunikacija (COM(2010) 2020 final) – *Europa 2020.: Strategija za pametan, održiv i uključiv rast*, Preuzeto sa: http://publications.europa.eu/resource/cellar/6a915e39-0aab-491c-8881-147ec91fe88a.0004.02/DOC_1 (08/2019)

206. ***ECB*** (2013), European Central Bank, *Monthly Bulletin,* October, 2013, Preuzeto sa: https:// www.ecb.europa.eu/pub/pdf/mobu/mb201310en.pdf (11/2018)

207. ***ECB*** (2016), European Central Bank, Public Investment in Europe, *ECB Economic Bulletin*, Issue 2, 2016

208. ***Eckert, A.*** (2002), Retail price cycles and response asymmetry, *Canadian Journal of Economics,* Vol. 35, 52–77

209. ***Edelstein, P., Kilian, L.*** (2007), The Response of Business Fixed Investment to Changes in Energy Prices: A Test of Some Hypotheses about the Transmission of Energy Price Shocks, *The B.E. Journal of Macroeconomics,* De Gruyter, Vol. 7(1), 1-41

210. ***Edelstein, P., Kilian, L.*** (2009), How Sensitive are Consumer Expenditures to Retail Energy Prices?, *Journal of Monetary Economics*, Vol. 56 (6), 766–779

211. ***Ederington, H. et al.*** (2018), A review of the evidence on the relation between crude oil prices and petroleum product prices, *Journal of Commodity Markets*, Vol. 13, 1-15

212. ***Égert, B.*** (2011), Catching-up and inflation in Europe: Balassa–Samuelson, Engel's Law and other culprits, *Economic Systems*, Vol. 35 (2), 208-229

213. ***EIA*** (2016), Energy Information Administration, *International Energy Outlook 2016*, US Energy Information Administration, Office of Energy Analysis, US Department of Energy, Washington, DC.

214. ***EIA*** (2017), Energy Information Administration, *Europe Brent Spot Price FOB, Petroleum & other liquids, Data, Monthly, in US dollars per barrel*, Preuzeto sa: https://www.eia.gov/ dnav/pet/ hist_xls /RBRTEm.xls (12/2017)

215. ***EIHP,*** (2015), *Energija u Hrvatskoj 2015*, *Godišnji energetski pregled*, Energetski institut Hrvoje Požar, Preuzeto sa: http://www.eihp.hr/wp-content/uploads/2016/12/Energija2015.pdf (05/2017)

216. ***Elder, J.*** (2018), Price volatility: industrial production and special aggregates, *Macroeconomic Dynamics,* Vol. 22, 640-653

217. ***Elder, J., Serletis A.,*** (2009), Oil price uncertainty in Canada, *Energy Economics*, Vol. 31, 852-856

218. ***Elder, J., Serletis A.,*** (2010), Oil price uncertainty, *Journal of Money, Credit and Banking*, 42 (6), 1137-1159

219. ***Enders, W.*** (2010), Applied Econometric Time Series, 3rd edition, John Wiley and Sons,

220. ***Engle, R.F., Granger, C.W.*** (1987), Cointegration and error correction: representation, estimation and testing, *Econometrica*, Vol. 55, 251-276

221. ***Engle, R.F., Yoo, B.S.*** (1987), Forecasting and testing in Co-integrated Systems, Journal of *Econometrics*, Vol. 35, 143-159, North-Holland

222. ***Erjavec, N., Cota B., Bahovec V.*** (1999), Monetarno – kreditna aktivnost i realna privredna aktivnost u Republici Hrvatskoj: VAR Model, *Ekonomski pregled*, Vol. 50(11), 1488 -1504

223. ***Erjavec, N., Cota, B.*** (2003), Macroeconomic Granger – Causal Dynamics in Croatia: Evidence Based on a Vector Error – Correction Modeling Analysis, *Ekonomski pregled*, Vol. 54(1-2), 139-156

224. ***Esso, L.J., Keho, Y.*** (2016), Heading Energy consumption, economic growth andcarbon emissions: Cointegration and causality evidence from selected African countries, *Energy*, Vol. 114, 492-497

225. ***Eurostat*** (2018), *Statistics explained, Glossary: gross fixed capital formation*, Preuzeto sa: https://ec.europa.eu/eurostat/statistics-explained/index.php/Glossary:Gross_fixed_capital_ formation _(GFCF) (09/2018)

226. ***Eurostat***, *Employment and activity by sex and age* (2018), percentage, annual data, Active population and Total employment (resident population concept – LFS), from 20 to 64 years, Preuzeto sa: http://appsso.eurostat.ec.europa.eu/nui/submitViewTableAction.do (03/2018)

227. ***Eurostat***, *Final consumption expenditure of households by consumption purpose* - COICOP (2018), Preuzeto sa: http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=nama_10_co3_p3&lang=en, (03/2018)

228. ***Eurostat***, *GDP per capita in PPS* (2018), Indeks (EU=100), Preuzeto sa: https://ec.europa.eu/eurostat/tgm/table.do?tab=table&init=1&language=en&pcode=tec00114&plugin=1 (03/2018)

229. ***Eurostat***, *Harmonised unemployment rates (%) - monthly data* (2018), Unemployment acording to ILO definition, Seasonally adjusted data, Preuzeto sa: http://appsso.eurostat.ec.europa.eu/nui/submitView TableAction.do (02/2018)

230. ***Eurostat***, *HICP* (2018), Harmonised Indeks of Consumer Prices (2015 = 100) - annual dana, rate of change, Preuzeto sa: http://appsso.eurostat.ec.europa.eu/nui/submitViewTableAction.do (02/2018)

231. ***Eurostat***, *Labour cost levels by NACE Rev. 2 activity* (2018), Wages and salaries, Labour costs other than wages and salaries, in Euros per hour, Preuzeto sa: http://appsso.eurostat.ec.europa.eu/nui/show. do?dataset=lc_lci_lev&lang=en (04/2018)

232. ***Eurostat***, *Labour productivity per person employed and hour worked* (2018), Nominal labour productivity per hour worked, EU28=100, Preuzeto sa: https://ec.europa.eu/eurostat/tgm/refreshTableAction.do?tab=table&plugin=1&pcode=tesem160&language=en (03/2018)

233. ***Eurostat***, *Purchasing power parities (PPPs), price level indices and real expenditures for ESA 2010 aggregates* (2018), Preuzeto sa: http://appsso.eurostat.ec.europa.eu/nui/submitViewTable Action .do (07/2018)

234. ***Eurostat***, *Total investment to GDP ratio* (2018), Key indicators, Preuzeto sa: http://appsso.eurostat.ec.europa. eu/nui/submitViewTableAction.do (03/2018)

235. ***Eurostat***, *Unemployment by sex and age* (2018), annual average, total, Preuzeto sa: http://appsso.eurostat.ec. europa.eu/nui/show.do?dataset=une_rt_a&lang=en (02/2018)

236. ***Evans, C.L., Fisher, J.D.M.*** (2011), What are the implications of rising commodity for inflation and monetary policy? *Chicago Fed Letter* No. 286.

237. ***Ewing, B.T., Thompson, M.A.*** (2007), Dynamic cyclical comovements of oil prices with industrial production, consumer prices, unemployment, and stock prices, *Energy Policy*, Vol. 35 (11), 5535-5540

238. ***Ewing, B.T., Yang, B.*** (2009), Manufacturing and non-manufacturing employment, exchange rate and oil price: a US state-level time series analysis, *Ekonomik ve Sosyal Ara¸stırmalar Dergisi*, Vol. 5 (1), 1-22

239. ***Ezzati, A.*** (1976), Future OPEC Price and Production Strategies as Affected by its Capacity to Absorb Oil Revenues, *European Economic Review*, Vol. 8, 107-138

240. ***Fahrmeir, L., Kneib, T., Lang, S., Marx, B.*** (2013), *Regression: Models, Methods and Applications,* Berlin, Springer

241. ***Fallahi, F., Voia, M.C.*** (2015), Convergence and persistence in per capita en-ergy use among OECD countries: Revisited using confidence intervals, *Energy Economics*, Vol. 52, 246-253

242. ***Fattouh, B.*** (2007a), The Drivers of Oil Prices: The Usefulness and Limitations of Non-Structural model, the Demand_Supply Framework and Informal Approaches, Oxford Institute for Energy Studies, WMP 32

243. ***Fattouh, B.*** (2007b), OPEC pricing power: The need for a new perspective, In Helm, D. (ed.), *The new energy paradigm*. Oxford University Press, Oxford, UK. Forthcoming

244. ***Fattouh, B.,*** (2006), Spare Capacity and Oil Price Dynamics, *Middle East Economic Survey*, XLIX(5), 30 January

245. ***Fattouh, B., Kilian, L., Mahadeva, L.*** (2013), The Role of Speculation in Oil Markets: What Have We Learned So Far?, *Energy Journal*, Vol. 34(3), 7-33

246. ***Fattouh, B., Mahadeva, L.*** (2013), OPEC: What Difference Has it Made?, *Annual Review of Resource Economics*, Vol. 5 (1), 427-443

247. ***Ferderer, J.P.*** (1996), Oil Price Volatility and the Macroeconomy: A Solution to the Asymmetry Puzzle, *Journal of Macroeconomics,* Vol. 18, 1-16

248. ***Fields, G.S.*** (2011), Labor market analysis for developing countries, *Labour Economics*, Vol. 18 (1), 16-22

249. ***Finley, M.*** (2012), The Oil Market to 2030 - Implications for Investment and Policy, *Economics of Energy & Environmental Policy*, Vol. 1 (1), 25-36

250. ***Fischer, D., Gately, D., Kyle, J.*** (1975), The Prospects for OPEC: A Critical Survey of Models of the World Oil Market, *Journal of Development Economics*, Vol. 2, 363-386

251. ***Font Vivanco, D., McDowall, W., Freire-Gonzales, J., Kemp, R., van der Voet, E.*** (2016), The foundations of the environmental rebound effect and its contribution towards a general framework, *Ecological Economics*, Vol. 125, 60-69

252. ***Frank, R., Bernanke, B***. (2001), *Principles of Economics*, McGraw Hill Companies Inc., New York, USA

253. ***Frans, D.*** (2017), Oil demand in OECD has already peaked. When will he rest follow?, Roland Berger, Amsterdam, Preuzeto sa: https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=12&ved=2ahUKEwj5wKG41I_mAhUFsaQKHVUIAhg4ChAWMAF6BAgGEAI&url=https%3A%2F%2Fwww.rolandberger.com%2Fpublications%2Fpublication_pdf%2Froland_berger_peak_oil_demand_analyses.pdf&usg=AOvVaw0wNs54bCkun8Dvudilz-xg (08/2018)

254. Fred Economic data (2018), US, Federal Reserve Bank of St. Louis, Economic Research, *Producer Price Index for All Commodities,* Preuzeto sa: https://fred.stlouisfed.org/series/PPIACO (02/2018)

255. ***Friedman, M.*** (1956), *A Theory of the Consumption Function*, Princeton University Press

256. ***Fryer, D., Payne, R.*** (1986), Being unemployed: A review of the literature on the psychological experience of unemployment, *International Review of Industrial and Organizational Psychology*, 235-278

257. ***Galac, T., Ivičić, L., Dumičić, M.*** (2007), A Simple Model of Interest Rates in the Croatian Money Market, prepared for the *13th Dubrovnik Economic Conference* (Pre-Conference Day), Preuzeto sa: http://old.hnb.hr/dub-konf/13-konferencija/galac-ivicic-dumicic.pdf, (10/2018)

258. ***Galeotti, M., Lanza, A., Manera, M.*** (2003), Rockets and feathers revisited: an international comparison on European gasoline markets, *Energy Economics*, Vol. 25, 175-190

259. ***Gallie, D., Kostova, D., Kuchar, P.*** (2001), Social consequences of unemployment: an East-West comparison, *Journal of European Social Policy*, Vol. 11(1), 39-54

260. ***Gao, L. et al.*** (2014), How do oil price shocks affect consumer prices?, *Energy Economics*, Vol. 45, 313–323

261. ***Gärtner, M.*** (2009), *Macroeconomics*, 3rd edition, Prentice Hall, Pearson Education Ltd., Essex, England

262. ***Gately, D.*** (2004), OPEC's incentives for faster output growth. *The Energy Journal*, Vol. 25(2), 75-96

263. ***Gately, D., Huntington, H.*** (2002), The asymmetric effects of changes in price and income on energy and oil demand, *The Energy Journal,* Vol. 23(1), 19-58

264. ***Gavin, M.*** (1989), The stock market and exchange rate dynamics, *Journal of International Money and Finance,* Vol. 8, 181-200

265. ***Gelo, T.*** (2008), Makroekonomski učinci svjetskih energetskih cjenovnih šokova na hrvatsko gospodarstvo, *doktorska disertacija*, Sveučilište u Zagrebu, Ekonomski fakultet

266. ***Gelos, G., Ustyugova, Y.*** (2017), Inflation Responses to Commodity Price Shocks–How and Why Do Countries Differ? WP/12/225

267. ***Genc, T.S.*** (2018), OPEC and Demand Response to Crude Oil Prices, *Energy Economics*, Vol. 66, 238-246

268. ***Georgescu-Roegen, N.*** (1971), *The entropy law and the economic process*. Cambridge, MA, Harvard University Press

269. ***Georgescu-Roegen, N.*** (1975), Energy and economic myths, *Southern economic journal*, Vol. 41 (3), 347-381

270. ***Gisser, M., Goodwin, T.*** (1986), Crude Oil and the Macroeconomy: Tests of Some Popular Notions, *Journal of Money,Credit,and Banking*, Vol. 18(1), 95-103

271. ***GIZ*** (2014), Deutsche Gesellschaft für Internationale Zusammenarbeit, Inter*national Fuel Prices 2014*, Preuzeto sa: https://www.giz.de/expertise/downloads/giz-2015-en-ifp2014.pdf (06/2018)

272. ***Glass, V., Cahn, E. S.*** (1987), Energy price uncertainty over the business cycle, *Energy Economics*, Vol. 9, 257-264

273. ***Globan, T., Arčabić, V., Sorić, P***. (2014), Inflation in new EU member states: A domestically or externally driven phenomenon?, *EFZG working paper series*, Paper No. 14-05

274. ***Godby, R., Lintner, A.M., Stengos, T., Wandschneider, B***. (2000), Testing for asymmetric pricing in the Canadian retail gasoline market, *Energy Economics*, Vol. 22, 349-368

275. ***Goldberg, L.*** (1993), Exchange rates and investment in United States industry, *The Review of Economics and Statistics*, Vol. 75, 575-589

276. ***Goldberg, P.K.*** (1998), The Effects of the Corporate Average Fuel Efficiency Standards in the US, *Journal of Industrial Economics*, Vol. 46 (1), 1-33

277. ***Golombek, R., Irarrazabal, A.A., Ma, L.*** (2018), OPEC's market power: An Empirical Dominant Firm Model for the Oil Market, *Energy Economics,* Vol. 70, 98-115

278. ***Gómez, V.*** (2000). Revision-based Test for Direct versus Indirect Seasonal Adjustment of Aggregated Series, Doc. Eurostat/A4/SA/00/08

279. ***Gómez-Loscos, M., Gadea, D., Montañés, A.*** (2012), Economic growth, inflation and oil shocks: are the 1970s coming back?, *Applied Economics*, Vol. 44(35), 4575-4589

280. ***Gounder, R., Bartleet, M.*** (2007), Oil Price Shocks and Economic Growth: Evidence for New Zealand: 1989-2006, *Paper presented at the New Zealand Association of Economist Annual Conference*, Christchurch, 27-29 June, 2007.

281. ***Gozgor, G., Lau, C.K.M., Lu, Z.*** (2018), Energy consumption and economic growth: New evidence from the OECD countries, *Energy*, Vol. 153, 27-34

282. ***Grahovac, P.*** (2003), Dekomponiranje i agregatna upotreba BDP-a, poglavlje u knjizi, Družić,I. (ur.), *Hrvatski gospodarski razvoj*, Ekonomski fakultret Zagreb i Politička kultura, Zagreb, 77-89

283. ***Granger, C.W.J.*** (1969), Investigating Causal Causal Relations by Econometric Models and Cross Spectral Methods, *Econometrica*, Vol. 37, 424-438

284. ***Granger, C.W.J.*** (1988), Some recent developments in a concept of causality, *Journal of Econometrics,* Vol. 39, 199–211

285. ***Granger, C.W.J., Newbold, P.*** (1974), Spurious regressions in econometrics, *Journal of Econometrics,* Vol. 2, 111–120

286. ***Grasso, M., Manera, M***. (2007), Asymmetric error correction models for the oil-gasoline price relationship, *Energy Policy,* Vol. 35, 156–177

287. ***Greenspan, A.*** (2006), Statement of Alan Greenspan before the Committee on Foreign Relations United States Senate, June 7, 2006, Preuzeto sa: http://foreign.senate.gov/testimony/2006/GreenspanTestimony060607.pdf (12/2010)

288. ***Griffin, J. M.*** (1985), OPEC Behavior: A Test of Alternative Hypotheses, *American Economics Review*, Vol. 75 (5), 954-963

289. ***Grossman, G.M., Helpman, E.*** (1990), Trade, Innovation, and Growth, *American Economic Review*, Vol. 80 (2), 86-91

290. ***Grossman, G.M., Helpman, E.*** (1991), Quality Ladders in the Theory of Growth, *The Review of Economic Studies*, Vol. 58 (1), 43-61

291. ***Gu, J., Jansen, D.W.*** (2006), Evidence on asymmetric gasoline price responses from error correction models with GARCH errors, Mimeo

292. ***Guiso, L., Parigi, G.*** (1999), Investment and demand uncertainty, *Quarterly Journal of Economics,* Vol. 114, 185-227

293. ***Gujarati, D.N.*** (2003), *Basic Econometrics*, 4th edition, McGraw Hill Companies Inc., New York, USA

294. ***Gulen, S.G.*** (1996), Is OPEC a Cartel? Evidence from Cointegration and Causality Tests, *The Energy Journal*, Vol. 17(2), 43-57

295. ***Guo, H., Kliesen, K.L.*** (2005), Oil Price Volatility and U.S. Macroeconomic Activity, *Federal Reserve Bank of St. Louis Review*, Vol. 87(6), 669-683

296. ***Hajko V.*** (2017), The failure of Energy-Economy Nexus: A meta-analysis of 104 studies, *Energy*, Vol. 125, 771-787

297. ***Hajko V., Sebri, M., Al-Saidi, M., Balsalobre-Lorente, D.*** (2018), *The Economics and Econometrics of the Energy-Growth Nexus*, Chapter 1 - The Energy-Growth Nexus: History, Development and New Challenges, 1-46

298. ***Hall, C.A.S., Cleveland, C.J., Kaufmann, R.*** (1986), *Energy and Resource Quality: The Ecology of the Economic Process*, Wiley Interscience, New York

299. ***Hall, C.A.S., Klitgaard, K.A.*** (2006), The need for a new, biophysical-based paradigm in economicsfor the second half of the age of oil, *International Journal of Transdisciplinary Research*, Vol. 1 (1), 4-22

300. ***Hall, C.A.S., Klitgaard, K.A***. (2012), *Energy and the Wealth of Nations: Understanding the Biophysical Economy*, Springer

301. ***Hall, C.A.S., Lindenberger, D., Kümmel, R., Kroeger, T., Eichhorn, W.*** (2001), The need to reintegrate the natural sciences with economics, *BioScience,* Vol. 51, 663–673

302. ***Haltiwanger, J.C., Vodopivec, M.*** (2002), Gross worker and job flows in a transition economy: an analysis of Estonia, *Labour Economics*, Vol. 9, 601–630

303. ***Haltiwanger, J.C., Vodopivec, M.*** (2003), Worker flows, job flows and firm wage policies: an analysis of Slovenia, *Economics of Transition*, Vol. 11 (2), 253-290.

304. ***Hamilton, J.D.*** (1983), Oil and the Macroeconomy Since World War II, *Journal of Political Economy*, Vol. 91, 228-248

305. ***Hamilton, J.D.*** (1985), Historical Causes of Postwar Oil Shocks and Recessions, *The Energy Journal,* Vol. 6 (1), 97-116

306. ***Hamilton, J.D.*** (1988), A Neoclassical Model of Unemployment and the Business Cycle, *Journal of Political Economy*, Vol. 96, 593-617

307. ***Hamilton, J.D.*** (1996), This Is What Happened to the Oil Price-Macroeconomy Relationship, *Journal of Monetary Economics*, Vol. 38, 15-220

308. ***Hamilton, J.D***. (2000), What is an oil shock? *NBER working paper, no. 7755.*

309. ***Hamilton, J.D.*** (2001), A Parametric Approach to Flexible Nonlinear Inference, *Econometrica,* Vol. 69, 537-573

310. ***Hamilton, J.D.*** (2003), What is an oil shock?, *Journal of Econometrics*, Vol. 113, 363-398

311. ***Hamilton, J.D.*** (2008a), Oil and the Macroeconomy, in S. Durlauf and L. Blume (eds), *The New Palgrave Dictionary of Economics*, 2nd ed., Palgrave MacMillan Ltd., Preuzeto sa: http://dss.ucsd.edu/~jhamilto/JDH_palgrave_oil.pdf (05/2010)

312. ***Hamilton, J.D.*** (2008b), Understanding Crude Oil Prices, *NBER Working Paper Series*, Working Paper No. 14492.

313. ***Hamilton, J.D.*** (2009), Causes and Consequences of the Oil Shock of 2007-08, *NBER Working Paper Series*, Working Paper No. 15002.

314. ***Hamilton, J.D.*** (2010), Nonlinearities and the Macroeconomic Effects of Oil Prices, *NBER Working Paper Series*, Working Paper No. 16186

315. ***Hamilton, J.D.*** (2011), Historical Oil Shocks, *NBER Working Paper Series,* Working Paper No. 16790

316. ***Hamilton, J.D., Herrera A.M.,*** (2004), Oil Shocks and Aggregate Macroeconomic Behaviour: The Role of Monetary Policy, *Journal of Money, Credit and Banking,* Vol. 36, 265-286

317. ***Hannan, E.J., Quinn, B.G.*** (1979), The Determination of the order of an autoregression, *Journal of the Royal Statistical Society*, Series B, Vol. 41, 190-195

318. ***Hartwick, J.M.*** (1978), Substitution Among Exhaustible Resources and Intergenerational Equity, *Review of Economic Studies*, Vol. 45 (2), 347-354

319. ***He, Y., Wang, S., Lai, K.K.*** (2010), Global economic activity and crude oil prices: A cointegration analysis, *Energy Economics*, Vol. 32, 868-876

320. ***Hegerty, S.W.*** (2015), Oil-Price Volatility and Macroeconomic Spllovers in Central and Eastern Europe: Evidence from a Multivariate GARCH Model, *Zagreb International Review of Economics & Business*, Vol. 18 (2), 31-44

321. ***Henriques, I., Sadorsky, P.*** (2011), The effect of oil price volatility on strategic investment, *Energy Economics*, Vol. 33, 79-87

322. ***Herrera, A.M., Karaki, M.B., Rangaraju, S.K.*** (2019), Oil price shocks and U.S. economic activity, *Energy Policy*, Vol. 129, 89-99

323. ***Herrera, A.M., Lagalo, L.G., Wada, T.*** (2011), Oil price shocks and industrial production: is the relationship linear?*, Macroeconomic Dynamics,* Vol. 15 (S3), 472-497

324. ***Herrera, A.M., Pesavento, E.*** (2009), Oil Price Shocks, Systematic Monetary Policy and the 'Great Moderation', *Macroeconomic Dynamics*, Vol. 13(1), 107-137

325. ***Herrera, A.M., Rangaraju, S.K***. (2018), The Effect of Oil Supply Shocks on U.S. Economic Activity: What Have We Learned?, *SSRN Electronic Journal*, 2018, Preuzeto sa: https://doi.org/10.2139/ssrn.3170422 (05/2019)

326. ***HGK*** (2015), Hrvatska gospodarska komora, Sektor za financijske institucije, poslovne informacije i ekonomske analize, Odjel za makroekonomske analize, *Utjecaj kretanja izvoza i uvoza nafte i naftnih derivata na robnu razmjenu RH*, Preuzeto sa: https://www.hgk.hr/documents/utjecaj-kretanja-izvoza-i-uvoza-nafte-i-naftnih-derivata-na-robnu-razmjenu-rh57b6f2cf939cb.pdf (08/2018)

327. ***HGK*** (2017a), Hrvatska gospodarska komora, *Kretanje BDP-a u Hrvatskoj - Izvori rasta i posljedice*, Sektor za financijske institucije, poslovne informacije i ekonomske analize, Preuzeto sa: https://www.hgk.hr/documents/kretanje-bdp-a-u-hrvatskoj-izvori-rasta-i-posljedice5addcdb7 bc19c .pdf (03/2017)

328. ***HGK*** (2017b), Hrvatska gospodarska komora, *Kretanje BDP-a u Hrvatskoj - napokon osjetniji rast*, Sektor za financijske institucije, poslovne informacije i ekonomske analize, Preuzeto sa: https://www.hgk.hr/documents/aktualna-tema-rast-bdp-a58beced171c45.pdf (03/2017)

329. ***HGK*** (2018), Hrvatska gospodarska komora, *Utjecaj investicija na kretanje BDP-a*, Preuzeto sa: https://www.hgk.hr/utjecaj-investicija-na-kretanje-bdp-a (05/2018)

330. ***Hirsch, R. L.*** (2008), Mitigation of maximum world oil production: Shortage scenarios, *Energy Policy,* 36(2), 881-889

331. ***HNB***, *Doprinosi domaće i neto inozemne potražnje rastu BDP-a* (2018), Hrvatska narodna banka, Preuzeto sa: https://www.hnb.hr/ analize-i-publikacije/redovne-publikacije/spf (06/2018)

332. ***HNB***, *Euroizacija* (2018), Udio deviznih depozita isključujući kunske depozite s valutnom klauzulom u ukupnim štednim i oročenim depozitima, Hrvatska narodna banka, Preuzeto sa: https://www.hnb.hr/documents/20182/120538/h-mp_15.xlsx/c099450a-6479-4cae-bb8895ddc0c bbf28 ? version=1.13 (02/2018)

333. ***HNB***, *Godišnje stope inflacije i doprinosi komponenata inflaciji potrošačkih cijena u Hrvatskoj* (2018), Hrvatska narodna banka, Analize i publikacije, Realni sektor, Dokumenti, Preuzeto sa: https://www.hnb.hr/documents/20182/ 121321/h-rs_11.xlsx (03/2018)

334. ***HNB***, Hrvatska narodna banka, *Godišnje izvješće*, razna godišta

335. ***HNB***, *Indeks realnog efektivnog tečaja uz potrošačke cijene* (2018), Hrvatska narodna banka, Statistika tečaja, Preuzeto sa: http://old.hnb.hr/tecajn1/hstatistika-tecaja.htm (02/2018)

336. ***HNB***, *Indeksi cijena* (2018), Hrvatska narodna banka, Preuzeto sa: https://www.hnb.hr/statistika/ statisticki-podaci/ odabrane-nefinancijske-statistike/indeksi-cijena (02/2018)

337. ***HNB***, *Indeksi efektivnih tečajeva kune* (2018), Hrvatska narodna banka, Statistika, Statistički podaci, Sektor inozemstva, Konkurentnost, Tablica H11, Preuzeto sa: https://www.hnb.hr/ documents/20182 /98f5bca9-e530-461d-9c25-eb4e8b5b0efc (03/2018)

338. ***HNB***, Indeksi efektivnih tečajeva kune (2018), Hrvatska narodna banka, Statistika tečaja, Tablica H11, Preuzeto sa: http://old.hnb.hr/tecajn1/ hstatistika-tecaja.htm (02/2018)

339. ***HNB***, *Indeksi potrošačkih cijena i proizvođačkih cijena industrije* (2018), Statistika, Statistički podaci, Cijene, Tablica J1, Preuzeto sa: https://www.hnb.hr/documents/20182/996b69a3-c057-4c09-a185-c01ab3d54fc4, (01/2018)

340. ***HNB***, *Indeksi potrošačkih cijena i proizvođačkih cijena industrije* (2018), Hrvatska narodna banka, Statistika, Statistički podaci, Cijene, Tablica J1, Preuzeto sa: https://www.hnb.hr/documents/ 20182/996b69a3-c057-4c09-a185-c01ab3d54fc4 (01/2018)

341. ***HNB***, *Kamatne stope kotirane na međubankarskom tržištu – ZIBOR* (2018), Hrvatska narodna banka, Statistika, Financijski sektor, Druge monetarne financijske institucje, Novčano tržište, Tablica G7b, Preuzeto sa: https: //www.hnb.hr/documents/20182/f386021b-965a-4949-a89e-356ef834d8a9 (05/2018)

342. ***HNB***, *Makroekonomka kretanja i prognoze* (2018), Hrvatska narodna banka, Preuzeto sa: https://www.hnb.hr/documents/20182/2164557/hMKP_05.pdf/513a0119-efb1-4ae3-b065-718b5f1 eafc3 (11/2018)

343. ***HNB***, *Međunarodne pričuve HNB-a i devizne pričuve banaka* (2018), Hrvatska narodna banka, Statistika, Financijski sektor, Međunarodne pričuve, Tablica H7, Preuzeto sa: https://www.hnb.hr/documents/20182/6ffecb49-45f4-4f33-ab75-34a6f930c058 (07/2018)

344. ***HNB***, *Monetarni i kreditni agregati* (2018), Hrvatska narodna banka, Statistika, Financijski sektor, Monetarni i kreditni agregati, Tablica A1, Preuzeto sa: https://www.hnb.hr/documents/20182/ffed056f-df13-4766-bc67-faa339 fd c6b1, (06/2018)

345. ***HNB***, *Okvir monetarne politike* (2018), Hrvatska narodna banka, Preuzeto sa: https://www.hnb.hr/temeljne-funkcije /monetarna-politika/okvir-monetarne-politike (10/2018)

346. ***HNB***, Prosječne mjesečne neto plaće (2018), Hrvatska narodna banka, Preuzeto sa: https://www.hnb.hr/statistika/statisticki-podaci/odabrane-nefinancijske-statistike/indeksi-placa, (07/2018)

347. ***HNB***, *Srednji tečaj HNB-a* (2018), Hrvatska narodna banka, Statistički podaci, Tablica G10a, Godišnji i mjesečni prosjeci srednjih deviznih tečajeva HNB-a, Preuzeto sa: https://www.hnb.hr/documents/20182/33ebeea1-3d13-4a42-b0fb-87223d026703 (03/2018)

348. ***HNB***, *Stopa anketne nezaposlenosti u usporedbi s tranzicijskim zemljama* (2018), Hrvatska narodna banka, Preuzeto sa: https://www. hnb.hr/documents/20182/121321/h-rs_06.xlsx (08/2018)

349. ***HNB***, *Valutna struktura plasmana drugih monetarnih financijskih institucija* (2018), Hrvatska narodna banka, Analize i publikacije, Monetarna politika, Dokumenti, Preuzeto sa: https://www.hnb.hr/ documents/20182/120538/h-mp_13.xlsx (01/2018)

350. ***Hoffman, D.L., Rasche, R.H.*** (1996), Assessing forecast performance in a cointegrated system, *Journal of Applied Econometrics*, Vol. 11, 495-517.

351. ***Hooker, M.*** (1999a), Are oil shocks inflationary? Asymetric and nonlinear specifications versus change in regime, *Journal of Money, Credit and Banking,* Vol. 34 (2), 540-561

352. ***Hooker, M.*** (1999b), Oil and the macroeconomy revisited, *Federal Reserve Board, FEDS Working Paper No. 99-43.,* Preuzeto sa: http://dx.doi.org /10.2139/ssrn.186014 (04/2009)

353. ***Hooker, M. A.*** (1996), What happened to the oil price-macroeconomy relationship?, *Journal of Monetary Economics,* Vol. 38, 195-213

354. ***Hooker, M. A.*** (1997), Exploring the Robustness of the Oil Price-Macroeconomy Relationship, Board of Governors of the Federal Reserve System, *Finance and Economics Discussion Paper* No. 97-56

355. ***Huang, R.D., Masulis, R.W., Stoll, H.R.*** (1996), Energy shocks and financial markets, *Journal of Futures Markets*, Vol. 16, 1-27

356. ***Huang, Y., Guo, F.*** (2007), The role of oil price shocks on China`s real exchange rate, *China Economc Review,* 18, 244-265

357. ***Hubbert, M. K.*** (1956), *Nuclear energy and the fossil fuels*. In American Petroleum Institute (ed.), Drilling and Production Practice, Washington, D.C., USA.

358. ***Hudson, E.A., Jorgenson, D.*** (1974), U.S. Energy Policy and Economic Growth, 1975-2000, *Bell Journal of Economics*, Vol. 5 (2), 461-514

359. ***Huntington, H.G.*** (1998), Crude Oil Prices and U.S. Economic Performance: Where Does the Assymetry Reside?, *The Energy Journal*, Vol. 19 (4), 107-132

360. ***Huntington, H.G., Al-Fattah, S.M., Huang, Z., Gucwa, M., Nouri, A. S.*** (2012), Oil Price Drivers and Movements: The Challenge for Future Research, Preuzeto sa: http://papers.ssrn.com/ sol3/ papers.cfm?abstract_id=2257675 (03/2014)

361. ***HZMO***, Hrvatski zavod za mirovinsko osiguranje, Publikacije, Statističke informacije Hrvatskog zavoda za mirovinsko osiguranje, *Kretanje broja osiguranika prema godinama i mjesecima*, razni brojevi i godišta, Preuzeto sa: http://www.mirovinsko.hr/default.aspx?id=723 (03/2018)

362. ***HZZ***, Hrvatski zavod za zapošljavanje, Mjesečni statistički bilten, Stopa nezaposlenosti, mjesečna, razna godišta

363. ***HZZ***, *Nezaposlene osobe prema dobi i spolu* (2018), Hrvatski zavod za zapošljavanje, Statistika, Registrirana nezaposlenost, Nezaposlene osobe prema dobi i spolu, mjesečno i tromjesečno, Preuzeto sa: https://statistika.hzz.hr/ PovijesneSerije/Tablica_04.xls (03/2018)

364. ***HZZ***, *Registrirana nezaposlenost* (2018), Hrvatski zavod za zapošljavanje, Statistika, Preuzeto sa: https://statistika.hzz.hr/statistika.aspx?tip Izvjestaja=1 (07/2018)

365. ***IEA*** (2010a), International Energy Agency, *World Energy Outlook 2010 Factsheet*, Preuzeto sa: http://www.worldenergyoutlook.org/media/weowebsite/factsheets/factsheets-1.pdf (04/2011)

366. ***IEA*** (2010b), International Energy Agency, *World Energy Outlook 2010*, Preuzeto sa: https://www.iea.org/publications/freepublications/publication/weo2010.pdf (11/2018)

367. ***IEA*** (2016), International Energy Agency, *Key World Energy Statistics*, Preuzeto sa: https:// www.iea.org/publications/freepublications/publication/KeyWorld2016.pdf (03/2017)

368. ***Imarhiagbe, S.*** (2010), Impact of oil prices on stock markets: empirical evidence from selected major oil producing and consuming countries, *Journal of Finance and Banking Issues,* Vol. 4 (4)

369. ***Imran, K., Siddiqui, M.M.*** (2010), Energy Consumption and Economic Growth: A Case Study of Three SAARC Countries, *European Journal of Social Sciences*, Vol. 16 (2), 206-213

370. ***INA***, Industrija nafte d.d., *Godišnje izvješće 2017*, Preuzeto sa: https://www.ina.hr/UserDocs Images/dokumenti //INA_AR_2017_cro_30_4%20 FINAL_link.pdf (08/2018)

371. ***Ito, K.*** (2010), The Impact of Oil Price Volatility on Macroeconomic Activity in Russia, *Economic Analysis Working Papers*, Vol. 9 (5)

372. ***Ivanov, M.*** (2017), Odnos deviznog tečaja i kamatnih stopa u kontekstu uvođenja eura, *HUB analize,* Preuzeto sa: https://www.hub.hr/sites/default/files/inline-files/odnos_deviznog_tecaja_i_ kamatnih _stopa _u_kontekstu_uvodenja_eur1_vs_0.pdf (03/2018)

373. ***Ivanov, M., Čavrak, V.*** (2005), The credit channel of the transmission mechanism in the Republic of Croatia, *International Journal of Entrepeneurship and Small Business*, Vol. 3, 254-265

374. ***Ivičić, L. et al.*** (2008), Rezultati petoga HNB-ova anketiranja banaka, *HNB publikacije*, Preuzeto sa: http://old.hnb.hr/publikac/pregledi/p-024.pdf, (10/2018)

375. ***Jakovac, P.*** *(2013),* Empirical analysis on economic growth and energy consumption relationship in Croatia, *Economic Research*, Vol. 26 (4), 21-24

376. ***Jakovac, P., Vlahinić Lenz, N.*** (2015), Uloga energije s aspekta ekonomske teorije, *Ekonomski pregled*, 66 (6), 527-557

377. ***Jakovac, P., Vlahinić Lenz, N.*** (2016), *Energija i ekonomija u Republici Hrvatskoj: Makroekonomski učinci proizvodnje i potrošnje električne energije*, Ekonomski fakultet Sveučilišta u Rijeci

378. ***Jiménez-Rodríguez, R., Sánchez M.*** *(2005),* Oil price shocks and real GDP growth: empirical evidence for some OECD countries, *Applied Economics*, Vol. 37 (2), 201-228

379. ***Jin, G.*** (2008), The Imact of Oil Price Shock and Exchange Rate Volatility on Economic Growth: A Comparative Analysis for Russia, Japan and China, *Research Journal of International Studies*, Vol. 8, 98-111

380. ***Jo, S.*** (2012), *The effects of oil price uncertainty on the macroeconomy,* Preuzeto sa: http://www.bankof canada.ca/wp-content/uploads/2012/12/wp2012-40.pdf (07/2017)

381. ***Jobling, A., Jamasb, T.*** (2017), Price volatility and demand for oil: A comparative analysis of developed and developing countries, *Economic Analysis and Policy,*Vol. 53, 96-113

382. ***Johansen, S.*** (1991), Estimation and hypothesis testing of Cointegration Vector in Guassian Vector Autoregressive Models. *Econometrica,* Vol. 59, 1551-1580

383. ***Johansen, S.*** (1995), *Likelihood-based inference in Cointegration Vector Autoregressive Models*, Oxford: Oxford University Press

384. ***Johnson, R.N.*** (2002), Search costs, lags and prices at the pump, *Review of Industrial Organization*, Vol. 20, 33-50

385. ***Jones, C.M., Kaul G.*** (1996), Oil and the Stock Markets, *Journal of Finance*, Vol. 51 (2), Preuzeto sa: SSRN: http://ssrn.com/abstract=7805 (12/2009)

386. ***Jones, C.T.*** (1990), OPEC Behavior under Falling Prices: Implications for Cartel Stability, *Energy Journa*l, Vol. 11(3), 117-129

387. ***Jones, D.W., Leiby P. N.*** (1996), *The Macroeconomic Impacts of Oil Price Shocks: A Review of Literature and Issues*, Oak Ridge National Laboratory, prepared for U.S. Department of Energy, preuzeto sa: https://www.researchgate.net/profile/Donald_Jones8/publication/ 241373088_ THE_ MACROECONOMIC_IMPACTS_OF_OIL_PRICE_SHOCKS_A_REVIEW_OF_LITERATURE_AND_ISSUES/links/540390170cf2c48563b02eb3.pdf (08/2010)

388. ***Jones, D.W., Leiby P.N., Paik, I K.*** (2004), Oli Price Shocks and the Macroeconomy: What Has Been Learned Since 1996, *The Energy Journal*, Vol. 25, 1-32

389. ***Jones, L., Manuelli, R.*** (1990), A Convex Model of Equilibrium Growth: Theory and Policy Implications, *Journal of Political Economy*, Vol. 98 (5), 1008-1038

390. ***Jorgenson, D. W***. (1984), The Role of Energy in Productivity Growth, *The Energy Journal*, Vol. 5 (3), 11-26

391. ***Jovičić, G., Kunovac, D.*** (2017), What is Driving Inflation and GDP in a Small European Economy: The Case of Croatia, *HNB working papers,* W-49

392. ***Ju, K., Su, B., Zhou, D., Wu, J., Liu, L.*** (2016), Macroeconomic performance of oil price shocks: Outlier evidence from nineteen major oil-related countries/regions, *Energy Economics*, Vol. 60, 325-332

393. ***Jurčić, Lj.***, ***Čeh Časni, A.*** (2017), Personal consumption in Croatia, conference paper, *Ekonomska politika Hrvatske u 2017. godini*, zbornik radova, 24. tradicionalno savjetovanje ekonomista, Opatija, Hrvatska, 9.-11. studenoga 2016., Jurišić, S. (ur.), Preuzeto sa: https://www.researchgate.net/publication/310135280_PERSONAL_CONSUMPTION IN CROATIA (10/2018)

394. ***Jurčić, Lj., Jošić, H., Jošić, M.*** (2012), Empirijska analiza inozemnog duga Hrvatske: pristup korištenjem VAR modela, *Ekonomski pregled*, Vol. 63 (5-6), 265-290

395. ***Kahia M., Ben Aissa, M. S., Lanouar C.*** (2017), Renewable and non-renewable energy use - economic growth nexus: The case of MENA Net Oil Importing Countries, *Renewable and Sustainable Energy Reviews*, Vol. 71, 127-140

396. ***Kahn, G., Hampton, R.*** (1990), Possible monetary policy responses to the Iraqui oil shock, *Federal Reserve Bank Kansas City Economic Review,* Vol. 2, 19–32

397. ***Kalimeris, P., Richardson, C., Bithas, K.*** (2014), A meta-analysis investigation of the direction of the energy-GDP causal relationship: implications for the growthdegrowth dialogue, *Journal of Cleaner Production*, Vol. 67, 1–13

398. ***Kalymon, B.A.*** (1975), Economic incentives in OPEC oil pricing policy, *Journal of Development Economics*, Vol. 2 (4), 337-362

399. ***Kang, W., Penn, D., Zietz, J.*** (2015), The response of state employment to oil price volatility, *Journal of Economics and Finance*, Vol. 39 (3), 478–500

400. ***Karlsson, K.H., Li, Y., Shukur, G***. (2018), The Causal Nexus between Oil Prices, Interest Rates, and Unemployment in Norway Using Wavelet Methods, *Sustainability*, Vol. 10 (8), 1-15

401. ***Karrenbrock, J.D.*** (1991), The behavior of retail gasoline prices: symmetric or not?, *Federal Reserve Bank of St. Louis,* Vol. 73, 19–29

402. ***Katircioglu, S.T., Sertoglu, K., Candemir, M., Mercan, M***. (2015), Oil price movements and macroeconomic performance: Evidence from twenty-six OECD countries, *Renewable and Sustainable Energy Reviews*, Vol. 44, 257–270

403. ***Kaufmann, R.K., Bradford, A., Belanger, L.H., Mclaughlin, J.P., Miki, Y.*** (2008a), Determinants of OPEC Production: Implications for OPEC Behavior, *Energy Economics*, Vol. 30, 333-351

404. ***Kaufmann, R.K., Dees, S., Gasteuil, A., Mann, M.*** (2008b), Oil Prices: The Role of Refinery Utilization, Futures Market and non-linearities, *Energy Economics*, Vol. 30, 2609-2622

405. ***Kaufmann, R.K., Dees, S., Karadeloglou, P., Sanchez, M.*** (2004), Does OPEC matter? An econometric analysis of oil prices, *Energy Journal*, Vol. 25, 67–90

406. ***Kaufmann, R.K., Laskowski, C.*** (2005), Causes for an asymmetric relation between the price of crude oil and re ned petroleum products, *Energy Policy,* Vol. 33, 1587–1596

407. ***Kaufmann, RK., Ullman, B.*** (2009), Oil prices, speculation, and fundamentals: Interpreting causal relations among spot and futures prices, *Energy Economics,* Vol. 31, 550–558

408. ***Keane, M.P., Prasad E. S.*** (1996), The Employment and Wage Effects of Oil Price Changes: A Sectoral Analysis, *Review of Economics and Statistics,* Vol. 78, 389-399

409. ***Kennedy, P***. *(2003), A guide to Econometrics,* Wiley Blackwell, New Jersey

410. ***Khan, M.I., Yasmeen, T., Shakoor, A., Khan, N.B., Riaz, M***. (2017), 2014 oil plunge: Causes and impacts on renewable energy, *Renewable and Sustainable Energy Reviews,* Vol. 68 (1), 609-622

411. ***Khazzoom, J.D.*** (1980), Economic Implications of Mandated Efficiency in Standards for Household Appliances, *The Energy Journal*, Vol. 1 (4), 21-40

412. ***Kilian, L.*** (2008a), The economic effects of energy price shocks, *Journal of Economic Literature,* Vol. 46, 871.-909.

413. ***Kilian, L.*** (2008b), Exogenous oil supply shocks: How big are they and how much do they matter for the US economy? *Review of Economics and Statistics*, Vol. 90 (2), 216-240

414. ***Kilian, L.*** (2009), Not All Oil Price Shocks Are Alike: Disentangling Demand and Supply Shocks in the Crude Oil Market, *American Economic Review*, Vol. 99 (3), 1053-1069

415. ***Kilian, L.*** (2017), How the Tight Oil Boom Has Changed Oil and Gasoline Markets, *CEPR Discussion Paper No. DP11876*

416. ***Kilian, L., Hicks, B.*** (2013), Did unexpectedly strong economic growth cause the oil price shock of 2003-2008?, *Journal of Forecasting*, Vol. 32, 385–394

417. ***Kilian, L., Lee, T.K.*** (2014), Quantifying the speculative component in the real price of oil: the role of global oil inventories, *Journal of International Money and Finance*, Vol. 42, 71–87

418. ***Kilian, L., Lewis, L.T.*** (2011), Does the Fed Respond to Oil Price Shocks?, *The Economic Journal*, Vol. 121 (555), 1047—1072

419. ***Kilian, L., Murphy, D.P.*** (2012), Why agnostic sign restrictions are not enough: understanding the dynamics of oil market VAR models, *Journal of the European Economic Association*, Vol. 10, 1166–1188

420. ***Kilian, L., Murphy, D.P.*** (2014), The role of inventories and speculative trading in the global market for crude oil, *Journal of Applied Econometrics*, Vol. 29, 454-478

421. ***Kilian, L., Vigfusson, R.J.*** (2009), Pitfalls in Estimating Asymmetric Effects of Energy Price Shocks, Board of Governors of the Federal Reserve System*, International Finance Discussion Papers*, No 970

422. ***Kilian, L., Vigfusson, R.J.*** (2011a), Are the Responses of the U.S. Economy Asymmetric in Energy Price Increases and Decreases?, *Quantitative Economics,* Vol. 2 (3), 419-453

423. ***Kilian, L., Vigfusson, R.J.*** (2011b), Nonlinearities in the Oil Price-Output Relationship, *Macroeconomic Dynamics*, Vol. 15 (S3), 337-363

424. ***Kim, G., Vera, D.*** (2018), Recent drivers of the real oil price: Revisiting and extending Kilian's (2009) findings, *Energy Economics*, Vol. (82), 201-210

425. ***King, R., Rebelo, S***. (1990), Public Policy and Economic Growth: Developing Neoclassical Implications, *Journal of Political Economy*, Vol. 98 (5), 126-150

426. ***Knittel, C.R., Pindyck. R.S.*** (2013), The simple economics of commodity price speculation*, NBER Working Paper No. 18951*

427. ***Kocaaslan, O. K.*** (2019), Oil price uncertainty and unemployment, *Energy Economics*, Vol. 81, 577-583

428. ***Koetse, M.J., de Groot, H.L.F., Florax, R.J.G.M.*** (2008), Capital-energy substitution and shifts in factor demand: A meta-analysis, *Energy Economics*, Vol. 30 (5), 2236-2251

429. ***Kooros, S.K., Sussan, A.P., Semetesy, M.*** (2006), The Impact of Oil Prices on Employment, *International Research Journal of Finance and Economics*, Vol. 5, 136-154

430. ***Kose, N., Baimaganbetov, S.*** (2015), The Asymmetric Impact of Oil Price Shocks on Kazakhstan Macroeconomic Dynamics: A Structural Vector Autoregression Approach, *International Journal of Energy Economics and Policy*, Vol. 5(4), 1058-1064

431. ***Kovačević, Z., Šušnjar, I., Gelo, T.*** (2014), Utjecaj kretanja cijena naftnih derivata na tržište automobila u Republici Hrvatskoj, *Ekonomska misao i praksa,* Vol. 1, 105-126

432. ***Kovenock, D., Widdows, K.*** (1998), Price leadership and asymmetric price rigidity, *European Journal of Political Economy*, Vol. 14 (1), 167-187

433. ***Kraft, E.*** (2003), Monetary Policy under Dollarization: The Case of Croatia, *Comparative Economic Studies,* Vol. 45(3), 256-277

434. ***Krichene, N.*** (2002), World Crude Oil and Natural Gas: A Demand and Supply Model, *Energy Economics,* Vol. 24 (6), 557-576

435. ***Krichene, N.*** (2006), World crude oil markets: Monetary policy and the recent oil shock, *International Monetary Fund Working Paper* No. 06/62.

436. ***Krichene, N.*** (2007), An oil and gas model, *International Monetary Fund Working Paper* No. 07/135

437. ***Krtalić, S., Benazić, M***. (2008) Crno zlato i inflacija: Upravo vjenčani?!, *Economics*, Vol. 15 (2), 281-306

438. ***Krtalić, S., Benazić, M***. (2010), Utjecaj promjene cijene nafte na gospodarsku aktivnost u Republici Hrvatskoj, *Ekonomski pregled*, Vol. 61 (1-2), 38-53

439. ***Krznar, I., Kunovac, D.*** (2010), Utjecaj vanjskih šokova na domaću inflaciju i BDP, *HNB istraživanja*, Preuzeto sa: https://www.hnb.hr/documents/20182/121348/i-028.pdf/073c5b08-ce30-4ba4-82fa-a95a66ff8b4a, (04/2017)

440. ***Kümmel, R.*** *(2011), The Second Law of Economics: Energy, Entropy, and the Origins of Wealth,* Springer

441. ***Kunovac, M.*** (2014), Employment protection legislation in Croatia, *Financial Theory and Practice,* Vol. 38 (2), 139-172

442. ***Kunovac, M., Pufnik, A.*** (2015), Adjustment of labor costs in Croatia during the crisis – results from WDN survey, HNB, Preuzeto sa: https://www.ecb.europa.eu/home/pdf/research/wdn/countryreports/WDN-Country_ReportCroatia.pdf?0cdff478771a6eaeaa7ea1774a78fb1e (10/2018)

443. ***Kwiatkowski, D., Phillips, P.C.B., Schmidt, P., Shin, Y.*** *(1992),* Testing The Null Hypothesis of Stationarity Against The Alternative of A Unit Root. How Sure Are We That Economic Time Series Have Unit Root?, *Journal of Econometrics,* Vol. 54(1-3), 159-178

444. ***Lamazoshvili, B.*** (2014), Effects of il price shocks on oil-importing developing economies: the case of Georgia and Armenia. Economics, *Education and Research Consortium Working Paper Series,* Working Paper No. E14/06

445. ***Lang, M., Krznar I.*** (2004), "Transmission Mechanism of Monetary Policy in Croatia", *referat na konferenciji "The Tenth Dubrovnik Economic Conference" u organizaciji Hrvatske narodne banke*, Dubrovnik, Preuzeto sa: http://www.hnb.hr/dub-konf/10-konferencija-radovi/lang-krznar.pdf. (05/2010)

446. ***Lanza, A.*** (1991), Speed of adjustment and market structure: a study of the gasoline market in Germany, *Oxford Institute for Energy Studies, Working Papers-Energy Economics*, No. 14

447. ***Lardic, S., Mignon, V.*** (2006), The Impact of Oil Prices on GDP in European Countries: An Empirical Investigation Based on Asymmetric Cointegration, *Energy Policy*, Vol. 30, 3910-3915

448. ***Lartey, E.K.K.*** (2008), Capital Inflows, Resource Reallocation and the Real Exchange Rate, *International Finance*, Vol. 11 (2), 131 – 152

449. ***Le Blanc, M., Chinn, M.D.*** (2004), Do high oil prices presage inflation? The evidence from G-5 countries, *Business Economics,* Vol. 34, 38–48

450. ***Leahy, J.V., Whited, T.M.*** (1996), The effect of uncertainty on investment: some stylized facts, *Journal of Money, Credit and Banking,* Vol. 28 (1), 64–83

451. ***Leduc, S., Sill, K***. (2004), A quantitative analysis of oil-price shocks, systematic monetary policy, and economic downturns, *Journal of Monetary Economics*, Vol. 51 (4), 781-808

452. ***Lee, C.C.*** (2005), Energy consumption and GDP in developing countries: a cointegrated panel analysis, *Energy Economics*, Vol. 27 (3), 415-427

453. ***Lee, J., Song J.*** (2009), Nature of Oil Price Shocks and Monetary Policy, *NBER Working Paper 15306*

454. ***Lee, K., Ni, S.*** (2002), On the Dynamic Effects of Oil Price Shocks: A Study Using Industry Level Dana, *Journal of Monetary Economics*, Vol. 49, 823-852

455. ***Lee, K., Ni, S., Ratti, R.A***., (1995), Oil Shocks and the Macroeconomy: The Role of Price Variability, *Energy Journal*, Vol. 16, 39-56

456. ***Lescaroux, F***. (2011), Dynamics of final sectoral energy demand and aggregate energy intensity, *Energy Policy*, Vol. 39, 66-82

457. ***Levy Yeyati, E.*** (2006), Financial Dollarization: Evaluating the Consequences, *Economic Policy*, Vol. 21(45), 61–118

458. ***Lewis, M.S.*** (2011), Asymmetric price adjustment and consumer search: an examination of retail gasoline market, *Journal of Economics and Management Strategy,* Vol. 20, 409-449

459. ***Lilien, D.*** (1982), Sectoral Shifts and Cyclical Unemployment, *Journal of Political Econom,* Vol. 90, 777-793

460. ***Lim, J.J.*** (2013), Institutional and Structural Determinants of Investment Worldwide, The World Bank, Development Economics Prospects Group, *Policy Research Working Paper 6591*

461. ***Lin E.Y.Y., Chen P.Y., Chen C.C.*** (2013), Measuring green productivity of country:A generalized metafrontier Malmquist productivity index approach, *Energy*, Vol. 55, 481-488

462. ***Lin, J.L., Tsay, R.S.*** (1996), Co-integration constraint and forecasting: an empirical examination, *Journal of Applied Econometrics*, Vol. 11, 519-538

463. ***Liu, M.-H., Margaritis, D., Tourani-Rad, A.*** (2010), Is there an asymmetry in the response of diesel and petrol prices to crude oil price changes? Evidence from New Zeland, *Energy Economics,* Vol. 32, 926-932

464. ***Lopez-Garcia, P. et al.*** (2014), Micro-based evidence of EU competitiveness: the CompNet database, *ECB Working Paper* (1634)

465. ***Löschel, A., Oberndorfer, U.*** (2009), Oil and Unemployment in Germany, *Journal of Economics and Statistics*, Vol. 229 (2-3), 146-162

466. ***Loungani, P.*** (1986), Oil Price Shocks and the Dispersion Hypothesis, *Review of Economcs and Statistics,* Vol. 58, 536-539

467. ***Lovrinović, I., Benazić, M.*** (2004), A VAR Analysis of Monetary Transmission Mechanism in the European Union", *Zagreb International Review of Economics and Business*, Vol. 7(2), 27-42

468. ***Lowther, J.*** (2003), Fleksibilnost radne snage i uloga hrvatskih socijalnih partnera u njezinu povećanju, *Financijska teorija i praksa,* Vol. 27 (4), 457-479

469. ***Luca, A., Petrova, I.*** (2008), What Drives Credit Dollarization in Transition Economies? *Journal of Banking and Finance*, Vol. 32 (5), 858-869

470. ***Lucas, R.*** (1988), On the mechanics of economic development, Journal of Monetary Economics, Vol. 22 (1), 3-42

471. ***Lucas, R.*** (1993), Making a Miracle, *Econometrica*, Vol. 61 (2), 251-272

472. ***Lütkepohl, H.*** (1982), Non-causality due to omitted variables, *Journal of Econometrics*, Vol. 19, 367-378

473. ***Lütkepohl, H.*** (2005), *Introduction to Multiple Time Series Analysis,* Springer, Berlin, Germany

474. ***Lütkepohl, H.., Xu, F.*** (2009), The Role Of The Log Transformation In Forecasting Economic Variables, *Cesifo Working Paper No. 2591*, Category 12: Empirical And Theoretical Methods

475. ***Lynch, M.*** (2002), Forecasting oil supply: theory and practice, *The Quarterly Review of Economics and Finance,* Vol. 42, 373–389

476. ***Mabro, R.*** (1992), OPEC and the Price of Oil, *Energy Journal*, Vol. 13, 1-17

477. ***Maddala, G.S.*** (2001), *Introduction to Econometrics,* John Wiley & Sons

478. ***Malanima, P.*** (2014), Energy in History, poglavlje u *The Basic Environmental History,* ed. Agnoletti, M., Serneri, S.N., Springer International Publishing, Switzerland, 1-28

479. ***Malešević-Perović, L.*** (2009), Kointegracijski pristup analizi inflacije u Hrvatskoj, *Financijska teorija i praksa*, Vol. 33 (2), 201-218

480. ***Mandal, K., Bhattacharyy, I., Bhoi, B.B.*** (2012), Is the oil price pass-through in india any different? *Journal of Policy Modeling*, Vol. 34(6), 832–848

481. ***Mankiw, N.G.*** (2006), *Osnove ekonomije*, III. Izdanje, Mate d.o.o., Zagreb

482. ***Marić, Z., Maletić, I., Rukelj, D.*** (2011), Analiza agregatnih investicija i perspektiva njihova kretanja u Hrvatskoj s posebnim naglaskom na mogućnosti korištenja Europskih fondova, *Ekonomski pregled*, Vol. 62 (1-2), 3-34

483. ***Matković, T.*** (2011), *Obrasci tranzicije iz obrazovnog sustava u svijet rada u Hrvatskoj*, doktorska disertacija, Zagreb, Pravni fakulutet Sveučilišta u Zagrebu

484. ***McDonald, R., Siegel, D.R.*** (1986), The value of waiting to invest, *Quarterly Journal of Economics*, Vol. 101, 707-728

485. ***Mehra, Y.P., Petersen, J.D***., (2005), Oil prices and consumer spending, *Federal Reserve Bank Richmond Economic Quarterly*, Vol. 91(3), 634-640

486. ***Menegaki, A.N.*** (2014), On energy consumption and GDP studies; A meta-analysis of the last two decades, *Renewable and Sustainable Energy Reviews*, Vol. 29(0), 31-36

487. ***Meyer, J., von Cramon-Taubadel, S.*** (2004), Asymmetric Price Transmission: A Survey, *Journal of Agricultural Economics*, Vol. 55 (3), 581–611

488. ***Meyler, A.*** (2009), The pass through of oil prices into euro area consumer liquid fuel prices in an environment of high and volatile oil prices, *Energy Economics,* Vol. 31, 867–881

489. ***Miguel, C., Manzano, B., Martin-Moreno, J.M.*** (2003), Oil Price Shocks and Aggregate Fluctuations, *The Energy Journal,* International Association for Energy Economics, Vol. 24(2), pages 47-62.

490. ***Miguel, C., Manzano, B., Martin-Moreno, J.M.*** (2005), Oil Shocks and the Business Cycle in Europe, *Studies on the Spanish Economy* 215, FEDEA

491. ***Milani, F.*** (2009), Expectations, learning, and the changing relationship between oil prices and the macroeconomy, *Energy Economics*, Vol. 31 (6), 827-837

492. ***Miller, K.D.*** (1998), Economic exposure and inegrated risk management*, Strategic Management Journal,* Vol. 19, 497-514

493. ***Mishkin, F.S.*** (1995), Symposium on the monetary transmission mechanism, *Journal of Economic Perspectives*, Vol. 9 (4), 3-10

494. ***Mishkin, F.S.*** (1996), The channels of monetary transmission: lessons for monetary policy, *NBER Working paper No. 5464*, National Bureau of Economic Research

495. ***Mishkin, F.S.*** (2001), The transmission mechanism and the role of asset prices in monetary policy, *NBER Working paper No. 8617,* National Bureau of Economic Research

496. ***Moebert, J.*** (2007), Crude oil price determinants, *Technical Report 186*, Department of Economics, *Darmstadt University of Technology*

497. ***Monfort, J.O., Bellido, M.M., Cuestas, J.C.*** (2019), Oil prices, unemployment and the financial crisis in oil-importing countries: The case of Spain, *Energy*, forthcoming

498. ***Mork, K.A.*** (1989), Oil and the Macroeconomy When Prices Go Up and Down: An Extension of Hamilton's Results, *Journal of Political Economy,* Vol. 97, 740-744

499. ***Mork, K.A., Hall, R.E.*** (1980), Energy Prices, Inflation and Recession, 1974-1975, *The Energy Journal,* Vol. 14(4), 151-161

500. ***Mork, K.A., Olsen, O., Mysen, H.T.*** (1994), Macroeconomic Responses to Oil Price Increases and Decreaces in Seven OECD Countries, *The Energy Journal*, Vol. 15(4), 19-35

501. ***Morse, E.*** (2006), The Global Oil Market Outlook: Ten Lessons About the Petroleum Sector. Presentation given at the 2006 Summer Fuels Outlook Conference Washington, D.C., April 11, 2006.

502. ***Mory, J.F.*** (1993), Oil Prices and Economic Activity: Is the Relationship Symmetric?, *The Energy Journal*, Vol. 14, 151-161

503. ***Mrnjavac, Ž.*** (1997), Alternativni pokazatelji nezaposlenosti, *Ekonomska misao i praksa: časopis Fakulteta za turizam i vanjsku trgovinu Dubrovnik*, Vol. 6 (1), 71-91

504. ***Mrnjavac, Ž.*** (2011), Zaposlenost, nezaposlenost i plaće, u Čavrak, V. (ur.) *Gospodarstvo Hrvatske,* Zagreb, Politička kultura, 126-145

505. ***Murphy, D.J., Hall, C.A.S.*** (2010), Year in review: EROI or energy return on (energy) invested, *Annals of the New York Academy of Sciences*, Vol. 1185, 102–118

506. ***MZOE***, *Cijene naftnih derivata* (2018), Ministarstvo zaštite okoliša i energetike, podaci dostavljeni e-mailom 24.07.2018. prema zamolbi upućenoj 19.06.2018. Podatke dostavio gdin Štambuk Damir, Viši savjetnik – specijalist, Služba za razvoj energetskih tržišta i energetsku infrastrukturu, Sektor za energetska tržišta i infrastrukturu, energetsku učinkovitost i obnovljive izvore energije

507. ***Naka, A., Tufte, D***. (1997), Examining impulse response functions in cointegrated systems, *Applied Economics,* Vol. 29 (12), 1593-1603

508. ***Narayan, P.K., Narayan, S.*** (2007), Modelling oil price volatility, *Energy Policy,* Vol. 35, 6549-6553

509. ***Narayan, P.K., Narayan, S.*** (2010), Modelling the impact of oil prices on Vietnams stock prices, *Applied Energy*, Vol. 87, 356-361

510. ***Narayan, P.K., Sharma, S., Poon , W.C., Westerlund, J.*** (2014), Do oil prices predict economic growth? New global evidence, *Energy Economics*, Vol. 41, 137-146

511. ***Narayan, P.K., Stephan Popp, S.*** (2012), The energy consumption-real GDP nexus revisited: Empirical evidence from 93 countries, *Economic Modelling*, Vol. 29, 303–308

512. ***Nestić, D.*** (2015), Ključni problemi hrvatskog tržišta rada, Zaposlimo Hrvatsku! Strateške smjernice za rast zaposlenosti, Vidović, Davorko (ur.), Zagreb: Hrvatska gospodarska komora (HGK), 43-58

513. ***Nestić, D., Lovrinčević, Ž., Mikulić, D.*** (2001), Plaće u Hrvatskoj - stanje i makroekonomske implikacije različitih scenarija budućih kretanja, *Ekonomski pregled*, Vol. 52 (1-2), 234-277

514. ***Nestić, D., Rubil, I., Tomić, I.*** (2015), Analiza razlika u plaćama između javnog sektora, poduzeća u državnom vlasništvu i privatnog sektora u Hrvatskoj 2000.-2012., *Privredna kretanja i ekonomska politika*, Vol. 24 (1/136), 7-51

515. ***Nestić, D., Tomić, I.*** (2014), The NEET population in Croatia: characteristics and dynamics, LSEE Research Network on Social Cohesion in SEE 2nd conference "Post-crisis recovery in South Eastern Europe: policy challenges for social and economic inclusion", London, UK, 27.-28.03.2014.

516. ***Newbery, D.M.G.*** (1981), Oil Prices, Cartels and the Problem of Dynamic Inconsistency, *Economic Journal*, Vol. 91, 617-646

517. ***Newell, R., Jaffe, A., Stavins, R.*** (1999). The Induced Innovation Hypothesis and Energy-Saving Technological Change, *The Quarterly Journal of Economics*, Vol. 114 (3), 941-975

518. ***Nikolic, J., Rubil, I., Tomić, I.*** (2015), Changes in Public and Private Sector Pay Structures in Two Emerging Market Economies during the Crisis, *EIZ Working Papers*, EIZ-WP-1403, Zagreb

519. ***Noel, M.*** (2006), Asymmetric cost passthrough in cycling retail gasoline markets: analysis under the correct counterfactual, Mimeo

520. ***Noel, M.*** (2007), Edgeworth price cycles, cost-based pricing, and sticky pricing in retail gasoline markets, *Review of Economics and Statistics,* Vol. 89, 324–334

521. ***Noel, M.*** (2009), Do retail gasoline prices respond asymmetrically to cost shocks? The in uence of Edgeworth cycles, *RAND Journal of Economics*, Vol. 40, 582–595

522. ***Obadić, A.*** (2005a), Dezagregirana analiza tržišta rada Hrvatske prema stručnoj spremi i djelatnostima, *Ekonomija*, Vol. 11, 588-620

523. ***Obadić, A.*** (2005b), *Makroekonomika tranzicijskog tržišta rada – s posebnim osvrtom na Hrvatsku,* Zagreb, Politička kultura

524. ***Obadić, A., Smolić, Š***. (2007), Analiza radnog kontingenta i ekonomska aktivnost stanovništva Hrvatske, *EFZG working paper series*, No.11

525. ***Obadić, A., Tica, J.*** (ur.) (2016), *Gospodarstvo Hrvatske,* Udžbenici Sveučilišta u Zagrebu, Ekonomski fakultet Sveučilišta u Zagrebu, Sveučilišna tiskara d.o.o., Zagreb

526. ***Ockwell, D.G.*** (2008), Energy and economic growth: Grounding our understanding in physical reality, *Energy Policy*, Vol. 36 (12), 4600-4604

527. ***Odusami, B.O.*** (2010), To consume or not: how oil prices affect the comovement of consumption and agregate wealth, *Energy Economics,* Vol. 32, 875-867

528. ***Oladosu, G.A., Leiby, P.N., Bowman, D.C., Uria-Martinez, R., Johnson, M.M.*** (2018), Impacts of oil price shocks on the United states economy: A meta-analysis of the oil price elasticity of GDP for net oil-importing economies, *Energy Policy*, Vol. 115, 523-544

529. ***Oladunjoye, O.*** (2008), Market structure and price adjustment in the U.S. wholesale gasoline markets, *Energy Economics,* Vol. 30, 937–961

530. ***Olomola, P. A., Adejumo, A. V.*** (2006), Oil price shocks and macroeconomic activities in Nigeria, *International Research Journal of Finance and Economics,* Vol. 3, 28-34

531. ***Omri, A.*** (2014), An International literature survey on energy-economic growth nexus: Evidence from country-specific studies, *Renewable and Sustainable Energy Reviews*, Vol. 38, 951–959

532. ***OPEC*** (2010), Organization of the Petroleum Exporting Countries, *World Oil Outlook*, Preuzeto sa: https://www.opec.org/opec_web/static_files_project/media/downloads/publications/WOO_2010.pdf (05/2015)

533. ***Özbek, L., Özlale, Ü.*** *(2010),* Analysis of real oil prices via trend-cycle decomposition, *Energy Policy,* Vol. 38, 3676- 3683

534. ***Ozturk, I.*** (2010), A literature survey on energy-growth nexus, *Energy Policy*, Vol. 38, 340-349

535. ***Paavola, J, Adger, W.N.*** (2005), Institutional ecological economics, *Ecological economics*, Vol. 53, 353-368

536. ***Papapetrou, E.*** (2001), Oil price shocks, stock market, economic activity and employment in Greece, *Energy Economics,* Vol. 23 (5), 511-532

537. ***Payne, J.*** (2002), Inflationary Dynamics of a Transition Economy: The Croatian Experience, *Journal of Policy Modeling*, Vol. 24 (3), 219-230

538. ***Payne, J.E.*** (2010), Survey of the international evidence on the causal relationship between energy consumption and growth, *Journal of Economic Studies*, Vol. 37 (1), 53-95

539. ***Peersman, G., Smets, F.*** (2001), The Monetary Transmission Mechanism in the Euro Area: More Evidence from VAR Analysis, *European Central Bank Working Paper Series No. 91*, Frankfurt: European Central Bank

540. ***Peersman, G., Van Robays, I.*** (2009), Oil and the Euro area economy, *Economic Policy*, Vol. 24 (60), 603–651

541. ***Peersman, G., Van Robays, I.*** (2012), Cross-Country Differences in the Effects of Oil Shocks, *Energy Economics*, Vol. 34 (5), 1532-1547

542. ***Perdiguero-Garcia, J.*** (2013), Symmetric or asymmetric oil prices? A meta-analysis approach, *Energy Policy*, Vol. 57, 389-397

543. ***Perišin, I., Šokman, A., Lovrinović, I.*** (2001), *Monetarna politika,* Fakultet ekonomije i turizma "Dr. Mijo Mirković", Pula

544. ***Perković, M., Puljiz, V.*** (2001), Ratne štete, izdaci za branitelje, žrtve i stradalnike rata u Republici Hrvatskoj, *Revija za socijalnu politiku*, Vol. 8(2), 235-238

545. ***Petrović Štefanac, D.*** (2012), Socijalno-etički okvir problema nezaposlenosti, *Crkva u svijetu*, Vol. 47 (3), 299-321

546. ***Phillips, P.C.B.*** (1986), Understanding Spurious Regressions in Econometrics, *Journal of Econometrics*, Vol. 33, 311-340

547. ***Phillips, P.C.B., Perron, P.*** (1988), Testing for a Unit Root in Time Series Regression, *Biometrika*, Vol. 75, 335-346

548. ***Phoumin, H., Kimura, S.*** (2014), Analysis on Price Elasticity of Energy Demand in East Asia: Empirical Evidence and Policy Implications for ASEAN and East Asia, *Economic Research Institute for ASEAN and East Asia (ERIA), Discussion Paper Series,* 2ERIA-DP-2014-05ERIA, Preuzeto sa: http://www.eria.org/ERIA-DP-2014-05.pdf (08/2019)

549. ***Pierce, J.L., Enzler, J.J.,*** (1974), The Effects of External Inflationary Shocks, *Brooking Papers on Economic Activity*, Vol. 1, 13-61

550. ***Pindyck, R.S.*** (1991), Irreversibility, Uncertainty and Investment, *Journal of Economic Literature*, Vol. 29, 1110-1148

551. ***Pindyck, R.S., Solimano, A.*** (1993), Economic Instavbility and Aggregate Investment, *NBER Working Paper No*. 4380

552. ***Pirlogea, C., Cice, C.*** (2012), Econometric perspective of the energy consumption and economic growth relation in European Union, *Renewable and Sustainable Energy Reviews*, Vol. 16 (8), 5718-5726

553. ***Pongrac, D., Šorić, K., Vojvodić Rosenzweig, V.*** (2007), Matematički model i programska podrška za određivanjevrijednosti granične obvezne pričuve kao instrumenta monetarne politike, *Financijska teorija i praksa,* Vol. 31 (3), 245-275

554. ***Popp, D.C.*** (2001), The effect of new technology on energy consumption, *Resource and Energy Economics*, Vol. 23 (3), 215-239

555. Promocija Plus, *Novi osobni automobili*, Izvješća, razne godine, Preuzeto sa: https://www.autonet.hr/media /2019/10/Trziste9-2019.pdf (07/2018)

556. ***Radchenko, S.I.*** (2005a), Lags in the response of gasoline prices to changes in crude oil prices: The role of short-term and long-term shocks, *Energy Economics,* Vol. 27, 573-602

557. ***Radchenko, S.I.*** (2005b), Oil price volatility and the asymmetric response of gasoline prices to oil price increases and decreases, *Energy Economics,* Vol. 27, 708-730

558. ***Radetzki, M.*** (2012), Politics – not OPEC interventions – explain oils extraordinary price history, *Energy Policy*, Vol. 46, 382-385

559. ***Rafiq, S., Salim, R., Bloch, H.*** (2009), Impact of crude oil price volatility oneconomic activities: an empirical investigation in the Thai economy, *Resources Policy*, Vol. 34 (3), 121-132

560. ***Rahman, S., Serletis A.,*** (2010), The asymmetric effects of oil price and monetary policy shocks: A nonlinear VAR approach, *Energy Economics*, Vol. 32, 1460-1466

561. ***Ramey, V.A., Vine, D.J.*** (2010), Oil, Automobiles, and the U.S. Economy: How Much Have Things Really Changed? *NBER Macroeconomics Annual,* Vol. 25 (1), 333-368

562. ***Ran, J., Voon, J.P.*** (2012), Does oil price shock affect small open economies? Evidence from Hong Kong, Singapore, South Korea and Taiwan, *Applied Economics Letters*, Vol. 19, 1599-1602

563. ***Rasche, R.H., Tatom, J.A.*** (1977), The Effects of the new Energy Regime on Economic Capacity, Production and Prices, Federal Reserve Bank of St. Lewis, *Economic Review*, Vol. 59 (4), 2-12

564. ***Rasmussen, T.N., Roitman, A.*** (2011), Oil Shocks in a Global Perspective: Are they Really that Bad?, *IMF Working Paper*, WP/11/194

565. ***Ratti, R., Vespignani, J.*** (2013), Crude oil prices and liquidity, the BRIC and G3 countries, *Energy Economics*, Vol. 39, 28-38

566. ***Ratti, R.A., Seol. J., Yoon, K.H.*** (2010), Relative energy price and investment by European firms, *Energy Economics,* Vol. 33, 721-731

567. ***Rebelo, S.*** (1991), Long-Run Policy Analysis and Long-Run Growth, *The Journal of Political Economy*, Vol. 99 (3), 500-521

568. ***Regnier, E***. (2007), Oil and energy price volatility, *Energy Economics,* Vol. 29, 405-427

569. ***Reilly, B., Witt, R.*** *(1998),* Petrol price asymmetries revisited*, Energy Economics,* Vol. 20, 297-308

570. ***Robalo, P.B., Salvado, J.C.*** (2008), Oil Price Shocks and the Portuguese Economy Since 1970s, *FEUNL Working Paper Series No. 529.,* Preuzeto sa SSRN: http://ssrn.com/abstract= 13091172 (12/2010)

571. ***Romer, P.R.*** (1986), Increasing Returns and Long-Run Growth, *The Journal of Political Economy*, Vol. 94 (5), 1002-1037

572. ***Romer, P.R.*** (1987), Growth Based on Increasing Returns Due to Specialization, *The American Economic Review*, Vol. 77 (2), 56-62

573. ***Romer, P.R.*** (1990), Endogenous Technological Change, Journal of Political Economy, Vol. 98 (5), 71-102

574. ***Rotemberg, J.J., Pindyck, R.*** (1984), Energy Price Shocks and Macroeconomic Adjustment, Poglavlje u knjizi: *Oil Shock: Policy Response and Implementation*, ed. Alm, A., Weiner, R., Cambridge: Ballinger Publishing Company

575. ***Rotemberg, J.J., Woodford, M.*** (1996), Imperfect Competition and the Effects of Energy Price Increases on Economic Activity, *Journal of Money, Credit and Banking,* Vol. 28, 549-577

576. ***Rubin, J.*** (2012), *The Big Flatline: Oil and the No-Growth Economy,* Palgrave McMillan, New York

577. ***Sadorsky, P.*** (1999), Oil price shocks and stock market activity, *Energy Economics,* Vol. 2, 449.-469

578. ***Sadorsky, P.*** (2000), The empirical relationship between energy futures prices andexchange rates, *Energy Economics,* Vol. 22, 253–266

579. ***Sadorsky, P.*** (2008), Assessing the impact of oil prices on firms of different sizes: Its tough being in the middle, *Energy Policy*, Vol. 36, 3854–3861

580. ***Salisu, A.A., Isah, K.O., Oyewole, O.J., Akanni, L.O.*** (2017), Modelling oil price-inflation nexus: The role of asymmetries, *Energy*, Vol. 125 (15), 97-106

581. ***Sampson, A.*** (1975), *The Seven Sisters: The Great Oil Companies and the World They Shaped,* New York: Viking Press

582. ***Samuelson, P.A.*** (1964.), Theoretical Notes on Trade Problems, *The Review of Economics and Statistics*, Vol. 46, 145-154

583. ***Samuelson, P.A., Nordhus, W.D.*** (2007), *Ekonomija*, XVIII. Izdanje, Mate d.o.o., Zagreb

584. ***Santini, D.J.*** (1985), The Energy Squeeze Model: Energy Price Dynamics in U.S. Business Cycles, *International Journal of Energy Systems*, Vol. 5, 18-25

585. ***Santini, D.J.*** (1992), Energy and Macroeconomy: Capital Spending Afte ran Energy Cost Shock, inJ. Moroney, ed., *Advances in the Economics of Energy and Resources*, vol. 7, Greenwich, CN: J.A.I. Press

586. ***Saunders, H.D.*** (1992), The Khazzoom-Brookes Postulate and Neoclassical Growth, *The Energy Journal*, Vol. 13 (4), 131-148

587. ***Sawyer, K.R., Nandha, M.*** (2006), How oil moves stock prices, *Working Paper Series, University of Melbourn*, Preuzeto sa: http://ssrn.com/abstract=910427 (12/2010)

588. ***Schubert, S.F., Turnovsky, S.J.*** (2010), The impact of oil prices on an oil-importing developing economy, *Journal of Development Economics*, Vol. 94, 18-29

589. ***Schult-Bornemann, K. H.*** (2012), Energy prognosis until 2030; reserves; transport fuels, *Fuel Systems for IC Engines*, 3-8

590. ***Schwarz, G.E.*** (1978), Estimating the dimension of a model, *Annals of Statistics*, Vol. 6 (2), 461-464

591. ***Scott, M.*** (1991), *A New View of Economic Growth,* Clarendon Press, Oxford

592. ***Sek, S.K., Teo, X.Q, Wong, N.W.*** (2015), A Comparative Study on the Effects of Oil Price Changes on Inflation, *Procedia Economics and Finance*, Vol. 26, 630-636

593. ***Shahbaz, M., Zakaria, M., Shahzad, H.S.J., Mahali, M.K.*** (2018), The Energy Consumption and Economic Growth Nexus in Top Ten Energy-Consuming Countries: Fresh Evidence from Using the Quantile-onQuantile Approach, *Energy Economics*, Vol. 71, 282-301

594. ***Shapiro, C., Stiglitz, J.E.*** (1984), Equilibrium unemployment as a worker discipline device, *The American Economic Review*, Vol. 74 (3), 433–444

595. ***Shin, D***. (1994), Do product prices respond symmetrically to changes in crude prices? *OPEC Energy Review*, Vol. 18, 137–157

596. ***Shioji, E., Uchino, T.*** (2010), Pass-Through of Oil Prices to Japanese Domestic Prices, *NBER Working Paper* No. 15888

597. ***Silvapulle, P., Moosa, I.A.,*** (1999), The relationship between spot and futures prices: evidence from the cruide oil market, *The Journal of Futures Markets, Vol.* 19, 175-193

598. ***Sims, C.A.*** (1980), Macroeconomics and reality, *Econometrica*, Vol. 48, 1-48

599. ***Smulders, S.*** (2004), International capital market integration: Implications for convergence, growth, and welfare, *International Economics and Economic Policy*, Vol. 1(2), 173-194

600. ***Solow, R.*** (1956), A contribution to the theory of economic growth, *Quarterly Journal of Economics*, Vol. 70, 65–94

601. ***Solow, R.*** (1974), Intergenerational Equity and Exhaustible Resources, Review of Economic Studies, Vol. 41 (5), 29-45

602. ***Sorić, P.*** (2012), Can Croatian Consumers Predict Inflation Dynamics?, *Privredna kretanja i ekonomska politika*, Vol. 131, 27-57

603. ***Sorm, V., Terrell, K.*** (2000), Sectoral restructuring and labour mobility: a comparative look at the Czech Republic, *Journal of Comparative Economics*, Vol. 28, 431-455

604. ***Speight, J.G.*** (2017), *Rules of Thumb for Petroleum Engineers*, Scrivener Publishing LLC., John Wiley & Sons, Inc.

605. ***Stavrev, E.*** (2009), Forces Driving Inflation in the New EU10 Members, *IMF Working Paper,* WP/09/51

606. ***Stern, D. I.*** (2011a), From Correlation to Granger Causality, Australian National University (ANU) - Crawford School of Public Policy, *Crawford School Research Paper* No. 13

607. ***Stern, D.I.*** (1993), Energy and economic growth in the USA: a multivariate approach*, Energy Economics,* Vol. 15 (2), 137–150

608. ***Stern, D.I.*** (2000), A multivariate cointegration analysis of the role of energy in the US macroeconomy, *Energy Economics,* Vol. 22, 267–283

609. ***Stern, D.I.*** (2010a), Modelling international trends in energy efficiency and carbon emissions, *Environmental Economics Research Hub,* Research Report 54

610. ***Stern, D.I.*** (2010b), The role of energy in economic growth, *CCEP Working paper*, 3.10

611. ***Stern, D.I.*** (2011b). The role of energy in economic growth, *Annals of the New York Academy of Sciences,* Vol. 1219 (1), 26-51

612. ***Stern, D.I., Cleveland, C.J.*** (2004), Energy and Economic Growth, *Rensselaer Working Paper in Economics* No. 0410. Rensselaer Polytechnic Institute, Troy, NY.

613. ***Stern, D.I., Kander, A.*** (2012). The Role of Energy in the Industrial Revolution and Modern Economic Growth, *The Energy Journal*, Vol. 33 (3)

614. ***Stevens, P.*** (2004), Nationa Oil Companies: Good or Bad? A Literature Survey, *CEPMLP Internet Journal*, Vol 14 (10)

615. ***Stiglitz, J.*** (1974), Growth with Exhaustible Natural Resources: The Competitive Economy, *Review of Economic Studies*, Vol. 41 (5), 139-152

616. ***Stiglitz, J.*** (1980), A Neoclassical Analysis of the Economics of Natural Resources, *NBER Worging Paper Series*, Reprint No. 77

617. ***Stjepanović, S.*** (2018), Relationship between energy consumption and economic growth in 30 countries in europe – panel, *Ekonomski pregled,* Vol. 69 (1), 43-57

618. ***Šolman, S.*** (2010), Uloga cestovnog prometa u turizmu Hrvatske, *Acta Turistica Nova*, Vol. 4 (2), 121-250

619. ***Šušnjar, I.*** (2014); Makroekonomski učinci elastičnosti potražnje za naftnim derivatima na hrvatsko gospodarstvo, *doktorska disertacija*, Sveučilište u Zagrebu, Ekonomski fakultet

620. ***Švec, M.*** (2009), Siva ekonomija u Hrvatskoj, *Financijska teorija i praksa*, Vol. 33 (4), 415-444

621. ***Tang, W., Wu, L., Zhang, Z.*** (2010), Oil price shocks and their short and long-term effects on the Chinese economy, *Energy Economics*, Vol. 32(S1), 3–14

622. ***Tappata, M.E.*** (2009), Rockets and Feathers: Understanding Asymmetric Pricing, *RAND Journal of Economics*, Vol. 40 (4), 673-687

623. ***Tatom, J.*** (1988), Are the macroeconomic effects of oil price changes symmetric? *Carnegie-Rochester Conference Series on Public Policy,* Vol. 14, 325-368

624. ***Tatom, J.*** (1993), Are There Useful Lessons from the 1990-91 Oil Price Shock?, *The Energy Journal*, Vol. 14 (4), 129-150

625. ***Taylor, J.B.*** (1995), The monetary transmission mechanism: an empirical framework, *Journal of Economic Perspectives*, Vol. 9 (4), 11-26

626. ***Taylor, J.B.*** (2001), The role of the exchange rate in monetary-policy rules, *American Economic Review*, Vol. 91 (2), 263-267

627. ***Teodorović, I.*** (2002), CEE Countries – Some Issues of EU Accession, *Ekonomski pregled*, Vol. 53 (11-12), 1087-1108

628. ***Tomić, I.*** (2014), Structural Unemployment in Croatia – How Important is the Occupational Mismatch?, *Ekonomska istraživanja*, Vol. 27 (1), 346-365

629. ***Tomić, I.*** (2015), Zaposlenost i nezaposlenost u Hrvatskoj – stanje, trendovi i okruženje, *Zaposlimo Hrvatsku! Strateške smjernice za rast zaposlenosti,* Vidović, Davorko (ur.), Zagreb: Hrvatska gospodarska komora (HGK), 21-41

630. ***Tomić, I., Domadenik, P***. (2012), Matching, adverse selection and labour market fl ows in a (post)transition setting: the case of Croatia, *Post-Communist Economies*, Vol. 24 (1), 39-72.

631. ***Tordo, S., Tracy B.S., Arfaa, N***. (2011), National Oil Companies and Value Creation, *World Bank Working Paper No. 21*, Preuzeto sa: https://siteresources.worldbank.org/INTOGMC/Resources/9780821388 310.pdf (07/2017)

632. ***Tsirimokos, C.*** (2011), *Price and Income Elasticities of Crude Oil DemandThe case of ten IEA countries, Master thesis* No 705, Swedish University of Agricultural Sciences, Faculty of Natural Resources and Agricultural Sciences, Department of Economics, ISSN 1401-4084, Uppsala 2011

633. ***Uhlig, H.*** (2005), What are the effects of monetary policy on output? Results from an agnostic identification procedure, *Journal of Monetary Economics*, Vol. 52 (2), 381-419

634. ***Ullrich, K.*** (2015), Oil: a price with many implications, Focus on Economics, *KFW Research*, Preuzeto sa: https://www.kfw.de/PDF/Download-Center/Konzernthemen/Research/PDF-Dokumente-Fokus-Volkswirtschaft/Fokus-englische-Dateien/Fokus-Nr.-94-Juni-2015_EN.pdf (8/2018)

635. ***Uri, N.D.*** (1980), Energy as a determinant of investment behavior, *Energy Economics*, Vol. 2, 179-183

636. ***Uri, N.D.*** (1996), Crude oil price volatility and unemployment in the United States, *Energy*, Vol. 21(1), 29-38

637. ***Uri, N.D., Boyd, R.*** (1996), The impact of crude oil price fluctuations on unemployment in the United States, *International Journal of Energy Research*, Vol. 20(11), 1003-1014

638. US Federal Reserve Bank of St. Louis (2018), Economic Research, *Producer Price Index for All Commodities*, Preuzeto sa: https://fred.stlouisfed.org/series/PPIACO (02/2018)

639. ***Valcarel, V.J., Wohar, M.E.*** (2013), Changes in the oil price-inflation pass-through, *Journal of Economics & Business*, Vol. 68, 24-42

640. ***Valente, S., Di Maria, C.*** (2008), Hicks meets Hotelling: The direction of technical change in capital-resource economies, *Environment and Development Economics*, Vol. 13 (6), 691-717

641. ***Van Els, P., Locarno, A., Morgan, J., Villetelle, J.*** (2001), Monetary Policy Transmission in the Euro Area: What Do Aggregate and National Structural Models Tell Us?, *European Central Bank Working Paper Series*, br. 94, Frankfurt: European Central Bank

642. ***Van Robays, I.*** (2012), Macroeconomic Uncertainity and the Impact of Oil Shocks, *European Central Bank, Working Paper Series*, No. 1479

643. ***Van Wijnbergen, S***. (1985), Oil price shocks, unemployment, investment and the current account: an intertemporal disequilibrium analysis, *The Review of Economic Studies*, Vol. 52 (4), 627–645

644. ***Veselica, V., Vojnić, D.*** (2001), Quo Vadis Croatia – Intefracijski trendovi i zemlje u tranziciji: Povijesna retrospektiva i aktualni trenutak, gdje je Hrvatska, *Ekonomski pregled*, Vol. 52 (11-12), 1185-1225

645. ***Vizek, M.*** (2006), Ekonometrijska analiza kanala monetarnog prijenosa u Hrvatskoj, *Privredna kretanja i ekonomska politika*, Vol. 16 (109), 29-61

646. ***Vizek, M., Broz, T.*** (2007), Modelling Inflation in Croatia, *The Institute of Economics Zagreb Working paper,* No. 0703.

647. ***Vlahinić, N., Jakovac, P.*** (2014), Revisiting the Energy Consumption-Growth Nexus for Croatia: New Evidence from a Multivariate Framework Analysis, *Contemporary Economics*, Vol. 8 (4), 435-452

648. ***Vlahinić-Dizdarević, N., Žiković, S***. (2010), The role of energy in economic growth: the case of Croatia, *Zbornik radova Ekonomskog fakulteta u Rijeci: časopis za ekonomsku teoriju i praksu*, Vol. 28 (1), 35-60

649. ***Vlahinić-Dizdarević, N., Žiković, S.*** (2011), *Ekonomija energetskog sektora: izabrane teme*, Ekonomski fakultet Sveučilišta u Rijeci (znanstvena knjiga)

650. ***Vujčić, B., Šošić, V.*** (2008), Does It Pay to Invest in Education in Croatia?, *EFZG Working Paper,* No. 07-08, Zagreb: Ekonomski fakultet Sveučilišta u Zagrebu

651. ***Vuk, B., Šimurina, I.*** (2009), *Energija u Hrvatskoj od 1945. do 2007. godine,* Energetski institut Hrvoje Požar, Zagreb

652. ***Walheer, B.*** (2018), Labour productivity growth and energy in Europe: A production-frontier approach, *Energy,* Vol. 152, 129-143

653. ***Walls, M.A.*** (1992). Modeling and forecasting the supply of oil and gas: A survey of existing approaches, *Resources and Energy,* Vol. 14 (3), 287-309

654. ***Wang, J.S.*** (2013), Oil price effects on personal consumption expenditures, *Energy Economics*, Vol. 36, 198-204

655. ***Wang, Y., Xiang, E., Cheung, A., Ruan, W., Hu, W.*** (2017), International oil price uncertainty and corporate investment: Evidence from China's emerging and transition economy, *Energy Economics,* Vol. 61 (C), 330–339

656. ***Ward, M.D., Ahlquist, J.S.*** (2018), *Maximum Likelihood for Social Science: Strategies for Analysis,* Cambridge University Press

657. ***Watkins, G.C.*** (2006), Oil scarcity: What have the past three decades revealed? *Energy Policy*, Vol. 34, 508-514

658. WB, *World Development Indicators* (2018), World Bank Households and NPISHs Final consumption expenditure per capita (constant 2010 US$), Preuzeto sa: https://dana.worldbank .org/indicator/NE.CON.PRVT.PC.KD?end=1999&locations=HR-CZ-DE-EE-HU-LV-LT-PL-SK-SI-GBUS&start= 1999&view=bar (10/2018)

659. ***White, H.*** (1980), A Heteroskedasticity-Consistent Covariance Matrix Estimator and a Direct Test for Heteroskedasticity, *Econometrica,* Vol. 48 (4), 817-838

660. ***Wilcox, J.A.*** (1983), Why Real Interest Rates Were So Low in the 1970s, *American Economic Review,* 44-53

661. ***Wirl, F., Kujundzic, A.*** (2004), The Impact of OPEC Conference Outcomes on World Oil Prices 1984-2001, *Energy Journal,* Vol. 25, 45-62

662. ***Wolf, C.*** (2009), Does Ownership Matter? The Performance and Efficiency of State Oil vs. Private Oil (1987-2006), *Energy Policy*, Vol. 37 (7), 2642-2652

663. ***Xiong, J., Wu, P.*** (2009), An analysis of forecasting model of crude oil demand based on cointegration and vector error correction model (VEC), *International Seminar on Business and Information Management*, ISBIM, 2008, 485-488

664. ***Yang, C. W., Hwang, M. J., Huang, B. N.*** (2002), An analysis of factors affecting price volatility of the US oil market, *Energy Economics,* Vol. 24, 107-119

665. ***Ye, M., Zyren, J., Shore, J., Burdette, M.*** (2005), Regional comparisons, spatial aggregation and asymmetry of price pass-through in US gasoline markets, *Atlantic Economic Journal*, Vol. 33, 179-192

666. ***Yoon, K.H., Ratti, R.A.*** (2011), Energy price uncertainty, energy intensity and firm investment, *Energy Economics,* Vol. 33, 67-78

667. ***Young, D.P.T.*** (1994), The nature of OPEC and oil price changes, *Energy Economics*, Vol. 16 (2), 107-114

668. ***Zavadska, M., Morales, L., Coughlanc, J.*** (2018), Brent crude oil prices volatility during major crises, *Finance Research Letters,* Available online 26 December 2018

669. ***Zelenika, R.*** (2000), *Metodologija i tehnologija izrade znanstvenog i stručnog djela*, IV. Izdanje, Udžbenici Sveučilišta u Rijeci, Sveučilište u Rijeci, Ekonomski fakultet u Rijeci, Rijeka

670. ***Zhang, D.*** (2008), Oil shock and economic growth in Japan: a nonlinear approach, *Energy Economics*, Vol. 30, 2374-2390

671. ***Zhang, D.*** (2014), International oil shocks and household consumption in China, *Energy Policy*, Vol. 75, 146-156

672. ***Zhang, D., Broadstock, D.C.*** (2014), Impact of International Oil Price Shocks on Consumption Expenditures in ASEAN and East Asia, *ERIA Discussion Paper 2014-24*

673. ***Zoli, E.*** (2009), Commodity Price Volatility, Cyclical Fluctuations, and Convergence: What is Ahead for Inflation in Emerging Europe?, *IMF Working Paper*, WP/09/41

674. ***Zon, A., Yetkiner, I.H.*** (2003), An endogenous growth model with embodied energy-saving technical change, *Resource and Energy Economics*, Vol. 25, 81-103

675. ***Žigman, A., Lovrinčević, Ž.*** *(2005)*, Monetarna politika ciljane inflacije i transmisijski mehanizam, *Ekonomski pregled*, Vol. 56 (7-8), 433-457

676. ***Žiković, S.***, ***Vlahinić-Dizdarević, N.*** (2011), Oil consumption and economic growth in small European countries, *Economic Research - Ekonomska Istraživanja*, Vol. 24 (3), 15-32

POPIS TABLICA

Tablica 2.1.3.1. Pregled istraživanja o uzročnosti potrošnje energije i gospodarskog rasta 46
Tablica 2.3.1.3.1.: Poredak prvih deset država najvećih proizvođača nafte (2000.-2015.) ... 107
Tablica 2.3.2.1.: Procjene cjenovne elastičnosti potražnje za naftom prema različitim studijama 113
Tablica 2.3.2.2.: Procjene dohodovne elastičnosti potražnje za naftom prema različitim studijama 115
Tablica 2.3.3.1.1. Identifikacija strukture naftnih šokova s obzirom na izvor promjene cijene 127
Tablica 3.4.1.: Struktura osobne potrošnje u Hrvatskoj (u %) 162
Tablica 3.4.2.: Usporedba udjela u ukupnoj potrošnji u 2006. i 2009. za odabrana EU gospodarstva 164
Tablica 3.4.3.: Prosječna godišnja osobna potrošnja po kućanstvu i izdaci za prijevoz u odnosu na kretanje prosječne nominalne plaće i cijena goriva, u kunama (tekuće cijene) 165
Tablica 3.5.1.: Struktura bruto domaćeg proizvoda u Republici Hrvatskoj (rashodna metoda, % BDP-a) 167
Tablica 3.6.1.: Ukupan broj benzinskih postaja u RH prema vlasništvu (1995. - 2015.) 176
Tablica 3.6.1.1.: Standardna devijacija cijena nafte, Eurosuper95 i Euro dizela od 1996. do 2015. godine 181
Tablica 3.6.2.1.: Trošarine na bezolovni benzin i dizelsko gorivo u periodu od 1995. do 2017., u kunama po litri 182
Tablica 3.6.2.2.: Visina naknade za financiranje rada HANDA-e 184
Tablica 3.6.2.3.: Trošarine u odabranim zemljama EU, u eurima na 1000 litara u 2018. 184
Tablica 3.6.2.4.: Iznos i udio prihoda od trošarina na naftne derivate u ukupnim prihodima od trošarina i ukupnim poreznim prihodima od 1995., 2000., 2005., 2010. i 2015. godine (u tisućama kuna) 185
Tablica 3.6.3.1.: Cijene naftnih derivata u zemljama u regiji (u €/l) na dan 23.03.2014. i duljina kopnene granice sa susjednom zemljom 187
Tablica 3.6.3.2.: Struktura maloprodajne cijene naftnih derivata u EU u €/l na dan 21.03.2014 188
Tablica 4.2.2.1.: Popis varijabli 216
Tablica 4.3.1.: Deskriptivna statistika korištenih tromjesečnih vremenskih nizova 222
Tablica 4.3.2.: Deskriptivna statistika korištenih mjesečnih vremenskih nizova 222

Tablica 4.4.1.1.: Rezultati testova jediničnog korijena za korištene vremenske nizove, tromjesečni podaci (1995:Q1-2015:Q4) 225
Tablica 4.4.1.2.: Rezultati Johansenovog testa kointegracije za VAR sustav jednadžbi (varijable: LBDP, LIPI, LREER, LOIL) 226
Tablica 4.4.1.3.: Testiranje optimalnog broja vremenskih odmaka (k) u modelu 227
Tablica 4.4.1.4.: LM test autokorelacije u VAR modelu 227
Tablica 4.4.1.5.: Matrica koeficijenata korelacije reziduala 228
Tablica 4.4.1.6.: Wald test o isključivanju vremenskog odmaka iz VAR modela 228
Tablica 4.4.1.7.: Konačan broj vremenskih odmaka u procijenjenim VAR modelima 229
Tablica 4.4.1.8.: Test heteroskedastičnosti reziduala u VAR modelu 229
Tablica 4.4.1.9.: Test normalnosti reziduala 230
Tablica 4.4.1.10.: Prikaz statistički značajnih rezultata Granger uzročnosti procijenjenih VAR modela, multivarijantni okvir 232
Tablica 4.4.1.11.: Rezultati Wald testa – bivarijantni okvir 233
Tablica 4.4.1.12.: Rezultati Wald testa – multivarijantni okvir 234
Tablica 4.2.1.13.: Rezultati Wald testa jednakosti procijenjenih parametara pokazatelja pozitivnih i negativnih promjena cijena nafte 234
Tablica 4.4.1.14.: Statistička značajnost dummy varijable KRIZA 236
Tablica 4.4.1.15.: Dekompozicija varijance varijable realni BDP (DLBDP) 238
Tablica 4.4.1.16.: Dekompozicije varijance varijable DLBDP 239
Tablica 4.4.1.17.: Korigirani koeficijenti determinacije BDP jednadžbi procijenjenih VAR sustava 240
Tablica 4.4.1.18.: Vrijednost Akaike (AIC) i Schwarz (SBC) informacijskih kriterija BDP jednadžbi procijenjenih VAR sustava 241
Tablica 4.4.2.1.: Rezultati testova jediničnog korijena za korištene vremenske nizove, mjesečni podaci (1995:M01-2015:M12) 242
Tablica 4.4.2.2.: Konačan broj vremenskih odmaka u procijenjenim VAR modelima 243
Tablica 4.4.2.3.: Rezultati Johansenovog testa kointegracije za VAR sustav jednadžbi (varijable: DLOILN, DLCPI, DLM1, DIR, DLNEER i DLIPI) 244
Tablica 4.4.2.4.: Prikaz statistički značajnih rezultata Granger uzročnosti procijenjenih VAR modela, multivarijantni okvir 244
Tablica 4.4.2.5.: Rezultati Wald testa – bivarijantni okvir 246
Tablica 4.4.2.6.: Rezultati Wald testa – multivarijantni okvir 247

Tablica 4.4.2.7.: Rezultati Wald testa jednakosti procijenjenih parametara pokazatelja pozitivnih i negativnih promjena cijena nafte 247
Tablica 4.4.2.8.: Vrijednosti procijenjenih parametara ispred varijable KRIZA 248
Tablica 4.4.2.9.: Dekompozicija varijance varijable DLCPI 251
Tablica 4.4.2.10.: Korigirani koeficijenti determinacije CPI jednadžbi procijenjenih VAR sustava 252
Tablica 4.4.2.11.: Vrijednost Akaike (AIC) i Schwarz (SBC) informacijskih kriterija CPI jednadžbi procijenjenih VAR sustava 252
Tablica 4.4.3.1.: Rezultati testova jediničnog korijena za korištene vremenske nizove, mjesečni podaci (2000:M01-2015:M12) 253
Tablica 4.4.3.2.: Konačan broj vremenskih odmaka u procijenjenim VAR modelima 254
Tablica 4.4.3.3.: Prikaz statistički značajnih rezultata Granger uzročnosti procijenjenih VAR modela, multivarijantni okvir 255
Tablica 4.4.3.4.: Rezultati Wald testa – bivarijantni okvir 256
Tablica 4.4.3.5.: Rezultati Wald testa – multivarijantni okvir 257
Tablica 4.4.3.6.: Rezultati Wald testa jednakosti procijenjenih parametara pokazatelja pozitivnih i negativnih promjena cijena nafte 257
Tablica 4.4.3.7.: Statistička značajnost dummy varijable KRIZA 258
Tablica 4.4.3.8.: Korigirani koeficijenti determinacije UNP jednadžbi procijenjenih VAR sustava 260
Tablica 4.4.3.9.: Vrijednost Akaike (AIC) i Schwarz (SBC) informacijskih kriterija UNP jednadžbi procijenjenih VAR sustava 261
Tablica 4.4.4.1.: Rezultati testova jediničnog korijena za korištene vremenske nizove, tromjesečni podaci (2000:Q1-2015:Q4) 262
Tablica 4.4.4.2.: Rezultati Johansenovog testa kointegracije za VAR sustav jednadžbi (varijable: LCONS, LDI, UNP, LOIL) 263
Tablica 4.4.4.3.: Konačan broj vremenskih odmaka u procijenjenim VAR modelima 263
Tablica 4.4.4.4.: Prikaz statistički značajnih rezultata Granger uzročnosti procijenjenih VAR modela, multivarijantni okvir 264
Tablica 4.4.4.5.: Rezultati Wald testa – bivarijantni okvir 265
Tablica 4.4.4.6.: Rezultati Wald testa – multivarijantni okvir 266
Tablica 4.4.4.7.: Rezultati Wald testa jednakosti procijenjenih parametara pokazatelja pozitivnih i negativnih promjena cijena nafte 267
Tablica 4.4.4.8.: Statistička značajnost dummy varijable KRIZA 267

Tablica 4.4.4.9.: Dekompozicije varijance varijable DLCONS 269
Tablica 4.4.4.10.: Korigirani koeficijenti determinacije CONS jednadžbi procijenjenih VAR sustava 270
Tablica 4.4.4.11..: Vrijednost Akaike (AIC) i Schwarz (SBC) informacijskih kriterija CONS jednadžbi procijenjenih VAR sustava 270
Tablica 4.4.5.1.: Rezultati testova jediničnog korijena za korištene vremenske nizove, tromjesečni podaci (1996:Q1-2015:Q4) 271
Tablica 4.4.5.2.: Konačan broj vremenskih odmaka u procijenjenim VAR modelima 272
Tablica 4.4.5.3.: Prikaz statistički značajnih rezultata Granger uzročnosti procijenjenih VAR modela, multivarijantni okvir 273
Tablica 4.4.5.4.: Rezultati Wald testa – bivarijantni okvir 274
Tablica 4.4.5.5.: Rezultati Wald testa – multivarijantni okvir 275
Tablica 4.5.5.6.: Rezultati Wald testa jednakosti procijenjenih parametara pokazatelja pozitivnih i negativnih promjena cijena nafte 276
Tablica 4.4.5.7.: Statistička značajnost dummy varijable KRIZA 277
Tablica 4.4.5.8.: Dekompozicije varijance varijable DLINV 279
Tablica 4.4.5.9.: Korigirani koeficijenti determinacije INV jednadžbi procijenjenih VAR sustava 280
Tablica 4.4.5.10.: Vrijednost Akaike (AIC) i Schwarz (SBC) informacijskih kriterija INV jednadžbi procijenjenih VAR sustava 281
Tablica 4.4.6.1.: Rezultati testova jediničnog korijena za korištene vremenske nizove, tromjesečni podaci (2000:M01-2015:M12) 283
Tablica 4.4.6.2.: Rezultati Johansenovog testa kointegracije (varijable: DLOIL, DLES95). 284
Tablica 4.4.6.3.: Rezultati Johansenovog testa kointegracije (varijable: DLOIL, DLDIESEL) 284
Tablica 4.4.6.4.: Procijenjene vrijednosti parametara u jednadžbi dugog roka 285
Tablica 4.4.6.5.: Procijenjene vrijednosti parametara jednadžbi kratkog roka 286
Tablica 4.4.6.6.: Procijenjene vrijednosti parametara asimetričnog modela korekcije grešaka, Wald test omjeri i njihove razine empirijske signifikantnosti 286
Tablica 4.4.6.7.: Procijenjene vrijednosti pomaka potrebnog za prilagodbu srednjoj vrijednosti 287

POPIS GRAFIKONA

Grafikon 2.1.1.1.: Postotne godišnje promjene realnog BDP-a, potrošnje energije i energetske intenzivnosti u svijetu 36
Grafikon 2.2.3.1.: Utjecaj porasta cijena nafte na krivulju potražnje za radom 71
Grafikon 2.3.6.1.: Cjenovna asimetrija kao posljedica razlike u jačini prilagodbe 95
Grafikon 2.3.6.2.: Cjenovna asimetrija kao posljedica razlike u brzini prilagodbe 95
Grafikon 2.3.6.3.: Cjenovna asimetrija kao posljedica razlike u jačini i brzini prilagodbe 96
Grafikon 2.3.1.3.1.: Proizvodnja nafte u tisućama barela dnevno 106
Grafikon 2.3.2.1.: Svjetska potrošnja energije po oblicima 2015. (u milijunima tona ekvivalenta nafte - mtoe) 110
Grafikon 2.3.2.2.: Potrošnja nafte u svijetu u tisućama barela nafte dnevno (1965.-2015.) .. 111
Grafikon 2.3.3.1.: Kretanje prosječnih godišnjih nominalnih (tekućih) cijena nafte u dolarima po barelu; WTI, Brent i Dubai, 1976.-2018. 121
Grafikon 2.3.3.2.: Povijesno kretanje realnih i nominalnih cijena nafte (1861.-2015.)* 122
Grafikon 3.1.1.: Realne godišnje razine i stope rasta BDP-a*, 1995.-2015. 134
Grafikon 3.1.2.: Doprinosi domaće i neto inozemne potražnje rastu BDP-a, 1998.-2015. (u %) 135
Grafikon 3.1.3.: Realne godišnje razine BDP-a (u cijenama 2010.) i godišnje realne cijene nafte* 136
Grafikon 3.1.5.: Procjena utjecaja cijena nafte na realni BDP, vremenska dekompozicija za period (2002.-2016.), medijan +/- 1 S.D. (68% interval pouzdanosti), godišnje stope rasta . 138
Grafikon 3.1.6.: Povijesna dekompozicija cijena nafte s komponentama koje su doprinijele njihovim promjenama, godišnje stope rasta 139
Grafikon 3.2.1.: Mjesečne stope inflacije (plava linija) i bazni indeks potrošačkih cijena (2010=100)* 141
Grafikon 3.2.2.: Godišnje stope inflacije i doprinosi komponenata inflaciji potrošačkih cijena u Hrvatskoj (2006M01-2015M12) 144
Grafikon 3.2.3.: Kretanje mjesečnih stopa inflacije i nominalnih cijena nafte u kunama po barelu* (1995M01-2015M12) 145
Grafikon 3.2.4.: Indeksi kretanja realnog i nominalnog efektivnog deviznog tečaja, 2010=100* 148
Grafikon 3.2.5.: Prosječni mjesečni bilateralni devizni tečajevi EUR/HRK i USD/HRK i prosječna mjesečna cijene nafte u USD po barelu 148

Grafikon 3.2.6.: Kretanje novčane mase (M1), u milijunima HRK, i mjesečne stope rasta.. 149
Grafikon 3.2.7.: Međunarodne devizne pričuve i novčana masa 150
Grafikon 3.2.8.: ZIBOR i prosječne mjesečne kamatne stope (IR) na Tržištu novca Zagreb 151
Grafikon 3.3.1.: Mjesečne stope nezaposlenosti u Hrvatskoj temeljem administrativnih izvora i ARS-a, 1998M01-2015M12..... 154
Grafikon 3.3.2.: Međunarodna usporedba godišnjih stopa nezaposlenosti unutar EU28, SAD i Japana, 2000., 2008. i 2015. 156
Grafikon 3.3.3.: Mjesečne stope nezaposlenosti u Hrvatskoj temeljem administrativnih izvora i ARS-a (1998M01-2015M12) u odnosu na kretanje realne cijene nafte (u USD po barelu) 157
Grafikon 3.3.4.: Broj nezaposlenih i kretanje realne neto plaće u kunama, 1995M01-2015M12 158
Grafikon 3.3.5.: Stope promjene zaposlenosti u poslovnom i javnom sektoru..... 159
Grafikon 3.4.1.: Kretanje vrijednosti osobne potrošnje (CONS) i BDP-a od 1995:Q1 do 2015:Q4 (u milijunima kuna, u stalnim cijenama 2010.)..... 160
Grafikon 3.4.2.: Kretanje realne osobne potrošnje u odnosu na realne cijene nafte u HRK.. 166
Grafikon 3.5.1.: Kretanje (i % promjene) realnog BDP-a i bruto investicija u fiksni kapital (u stalnim cijenama 2010., u mil. kn) 168
Grafikon 3.5.2. Kretanje realnih investicija (bruto investicija u fiksni kapital) u odnosu na kretanje realnih cijena nafte u HRK 169
Grafikon 3.5.3.: Realno* kretanje BDP-a i njegovih ključnih komponenti (rashodna metoda), 2008=100..... 170
Grafikon 3.6.1.: Ukupna potrošnja derivata nafte u Republici Hrvatskoj..... 173
Grafikon 3.6.2.: Potrošnja neposredne energije u prometu 174
Grafikon 3.6.3.: Prodaja (broj prvih registracija) novih automobila prema vrsti pogonskog goriva..... 175
Grafikon 3.6.1.1.: Cijena nafte (Brent), Euro dizela i Eurosuper95 bez poreza i trošarina(u kn/l) 178
Grafikon 3.6.1.2.: Prosječne mjesečne cijene nafte (Brent u kn/bbl, lijeva os), Euro dizela i Eurosuper95 (u kn/l, desna os) 180
Grafikon 3.6.2.1.: Cijene Euro dizela i Eurosuper95 u kn/l, sa i bez poreza i trošarina (lijeva os) i postotni udio poreza i trošarina u krajnjoj maloprodajnoj cijeni (desna os) od siječnja 2000. do prosinca 2015. 186
Grafikon 4.4.1.1.: Analiza stabilnosti VAR modela, jedinični krug s korijenima polinoma. 231

Grafikon 4.4.1.2.: Impulsne funkcije odziva varijable DLBDP na šok od jedne standardne devijacije u varijablama koje predstavljaju pokazatelje cijena nafte u svim procijenjenim VAR modelima 237
Grafikon 4.4.2.1.: Impulsne funkcije odziva varijable DLCPI na šok od jedne standardne devijacije u varijablama koje predstavljaju pokazatelje cijena nafte u svim procijenjenim VAR modelima 249
Grafikon 4.4.3.1.: Impulsne funkcije odziva varijable DUNP na šok od jedne standardne devijacije u varijablama koje predstavljaju pokazatelje cijena nafte u svim procijenjenim VAR modelima 259
Grafikon 4.4.4.1.: Impulsne funkcije odziva varijable DLCONS na šok od jedne standardne devijacije u varijablama koje predstavljaju pokazatelje cijena nafte u svim procijenjenim VAR modelima 268
Grafikon 4.4.5.1.: Impulsne funkcije odziva varijable DLINV na šok od jedne standardne devijacije u varijablama koje predstavljaju pokazatelje cijena nafte u svim procijenjenim VAR modelima 278

PRILOZI

Prilog 1.: Rješenje o odbijanju zahtjeva za pristup informacijama o tržišnim udjelima poduzetnika na maloprodajnom tržištu naftnih derivata u Republici Hrvatskoj

UP/I 053-01/18-01/001
580-06/88-2018-005

REPUBLIKA HRVATSKA
AGENCIJA ZA ZAŠTITU
TRŽIŠNOG NATJECANJA

CROATIAN COMPETITION AGENCY

KLASA: UP/I 053-01/18-01/001
URBROJ: 580-06/88-2018-004
U Zagrebu, 24. rujna 2018.

Službenik za informiranje na temelju članka 13. stavka 3. točke 1., članka 15. stavka 1. i članka 23. stavka 5. točke 2. Zakona o pravu na pristup informacijama („Narodne novine", broj 25/13., 85/15.) postupajući po zahtjevu za pristup informacijama korisnika Marine Lolić Čipčić, višeg predavača, Pomoćnice pročelnika za nastavu i međunarodnu suradnju, Sveučilište u Splitu, Sveučilišni odjel za stručne studije, Kopilica 5, 21000 Split, donosi

R J E Š E NJ E

I. Odbija se zahtjev za pristup informacijama korisnika Marine Lolić Čipčić, Pomoćnice pročelnika za nastavu i međunarodnu suradnju, Sveučilište u Splitu, Sveučilišni odjel za stručne studije, Kopilica 5, 21000 Split.

O b r a z l o ž e nj e:

Agencija za zaštitu tržišnog natjecanja (dalje: Agencija) zaprimila je putem elektroničke pošte, dana 27. kolovoza 2018. godine, zahtjev Marine Lolić Čipčić, Pomoćnice pročelnika za nastavu i međunarodnu suradnju, Sveučilište u Splitu, Sveučilišni odjel za stručne studije, Kopilica 5, 21000 Split (dalje: Podnositeljice zahtjeva) kojim se traže podatci temeljem Zakona o pravu na pristup informacijama („Narodne novine", broj 25/13., 85/15., dalje: ZPPI). S obzirom na to da je zahtjev upućen putem elektroničke pošte 27. kolovoza 2018. izvan redovnog radnog vremena, smatra se da je isti zaprimljen u Agenciji sljedećeg radnog dana, odnosno 28. kolovoza 2018. godine.

Podnositeljica zahtjeva zatražila je dostavu podataka o tržišnim udjelima poduzetnika - sudionika na maloprodajnom tržištu naftnih derivata u Republici Hrvatskoj tražeći od Agencije prikaz traženih podataka po godinama, a sve u razdoblju od 1995. do 2015. godine te se pri tome pozvala na istraživanje slične tematike koje je Agencija provela 2015. godine i objavila rezultate istraživanja. Navedeni zahtjev Podnositeljica zahtjeva postavila je sa svrhom pribavljanja podataka koji su joj potrebni za izradu doktorske disertacije.

Uvodno, Službenik za informiranje ističe kako, u najužem smislu, sadržaj konkretnog zahtjeva, Agencija ne posjeduje. Naime, Službenik za informiranje ističe kako je cilj navedenog istraživanja na koje je Podnositeljica zahtjeva ukazala bio utvrditi relevantne činjenice o načinu i mehanizmima određivanja maloprodajnih cijena goriva u razdoblju od godine dana nakon liberalizacije tržišta (konkretno, radi se o razdoblju veljača 2014. – veljača 2015.). Dakle, prikaz po godinama o tržišnim udjelima poduzetnika na maloprodajnom tržištu naftnih derivata, Agencija nema u posjedu stoga ne može niti omogućiti pristup takvim informacijama.

CROATIA, 10000 Zagreb, Savska cesta 41, tel.: +385 1 617 64 48, fax.: +385 1 617 64 50
e-mail: agencija.ztn@aztn.hr http://www.aztn.hr

No, Agencija je podatke potrebne za izradu navedenog istraživanja prikupljala sukladno ovlastima koje proizlaze iz odredbi Zakona o zaštiti tržišnog natjecanja („Narodne novine", broj 79/09. i 80/13.; u daljnjem tekstu: ZZTN) a za potrebe ispitivanja tržišta i utvrđivanja stanja na tržištu. Navedene podatke Agencija je prikupila putem anketnog upitnika, pri čemu su ih sami poduzetnici prilikom dostave izričito označili kao poslovnu tajnu. Navedeni podatci nisu javno objavljeni, iz razloga jer isti sadrže ili mogu sadržavati poslovnu tajnu poduzetnika. S druge strane, navedeni podatci, koje su poduzetnici dostavljali, po mišljenju Službenika za informiranje, potencijalno bi mogli koristiti Podnositeljici zahtjeva za izradu analize tržišnih udjela. Kako zatraženi podaci o tržišnim udjelima sudionika na mjerodavnom tržištu predstavljaju poslovnu tajnu u smislu članka 53. ZZTN-a, to je tijelo javne vlasti sukladno članku 16. stavku 1. ZPPI bilo dužno provesti test razmjernosti i javnog interesa. Zbog navedenog, Podnositeljici zahtjeva produžen je rok za daljnjih 15 dana u smislu članka 22. stavka 1. točke 4. i stavka 2. istog članka ZPPI te je o istom obaviještena dana 5. rujna 2018. godine.

Člankom 16. stavkom 2. ZPPI propisano je da je kod provođenja testa razmjernosti i javnog interesa tijelo javne vlasti dužno utvrditi da li se pristup informaciji može ograničiti radi zaštite nekog od zaštićenih interesa iz članka 15. stavka 2., 3. i 4. ZPPI, da li bi omogućavanjem pristupa traženoj informaciji u svakom pojedinom slučaju taj interes bio ozbiljno povrijeđen te da li prevladava potreba zaštite prava na ograničenje ili javni interes. Ako prevladava javni interes u odnosu na štetu po zaštićene interese, informacija će se učiniti dostupnom.

Člankom 53. stavkom 1. ZZTN-a propisano je da su članovi Vijeća i radnici Agencije dužni čuvati poslovnu tajnu, bez obzira na način na koji su je doznali, a obveza čuvanja poslovne tajne traje 5 godina nakon prestanka rada u Agenciji.

Člankom 53. stavkom 2. ZZTN-a propisano je što se smatra poslovnom tajnom, odnosno poslovnom tajnom iz stavka 1. navedenog članka smatra se osobito sve ono što je kao poslovna tajna određeno zakonom ili drugim propisom te sve ono što je poslovnom tajnom naznačio poduzetnik, pod uvjetom da Agencija to prihvati.

Nadalje, člankom 53. stavkom 3. ZZTN-a propisano je da se pod poslovnom tajnom iz stavka 1. navedenoga članka smatraju osobito poslovne informacije koje imaju stvarnu ili potencijalnu tržišnu vrijednost, a čije bi otkrivanje ili uporaba moglo rezultirati ekonomskom prednosti za druge poduzetnike. Dakle, radi se o informacijama koje su izričitom zakonskom odredbom utvrđene kao poslovna tajna, te u pogledu kojih postoji obveza Agencije na čuvanje poslovne tajne, stoga Službenik za informiranje smatra kako bi omogućavanjem pristupa tim informacijama izravno povrijedio zakonske odredbe o čuvanju poslovne tajne.

Stoga, u odnosu na konkretno istraživanje Agencije iz 2015., na koje se Podnositeljica zahtjeva pozvala u samom zahtjevu, ističe se da su rezultati istraživanja objavljeni na službenim stranicama Agencije pod naslovom „Nema pokazatelja koji ukazuju na značajne promjene marži trgovaca nakon liberalizacije", te se Podnositeljicu zahtjeva upućuje na službene tekstove objavljene na mrežnim stranicama Agencije, odnosno na tekstove u AZTN info objavljenih na temu konkretnog istraživanja. U odnosu na ostale informacije koje je Agencija prikupljala za potrebe provođenja predmetnog istraživanja, ističe se kako se radi o podatcima koji su od strane samih poduzetnika (kao ispitanika) označeni kao poslovna tajna, te kako bi odavanjem tih podataka neovlaštenim osobama mogle nastupiti štetne posljedice za gospodarske interese tih poslovnih subjekata.

Nadalje, Službenik za informiranje ističe kako je, nevezano za provedeno istraživanje na koje se Podnositeljica zahtjeva pozvala, Agencija u nekoliko predmeta prikupljala podatke na tržištu naftnih derivata, i to u predmetima ocjenjivanja dopuštenosti koncentracija poduzetnika na spomenutom tržištu. U takvim predmetima Agencija je prikupljala podatke od poduzetnika

sudionika koncentracije i određenog uzorka poduzetnika koji djeluju na mjerodavnom tržištu. Podatci koje su poduzetnici dostavljali u takvim postupcima strogo su naznačeni kao poslovne tajne od strane poduzetnika, a kao takve ih je Agencija i prihvatila u skladu s člankom 53. stavkom 2. ZZTN-a.

Iako se pojedini podatci iz navedenih predmeta ocjene dopuštenosti koncentracija poduzetnika mogu podvesti pod povijesne informacije odnosno informacije u smislu članka 53. stavka 5. alineja 2. ZZTN-a, Službenik za informiranje ipak smatra kako iste treba tumačiti kao poslovnu tajnu te ih kao takve učiniti nedostupnima trećim osobama.

Službenik za informiranje ističe kako u takvim predmetima Agencija postoje i akti koji predstavljaju prepisku s Europskom komisijom, a što je sukladno članku 53. st.3. ZZTN-a izričito naznačeno kao poslovna tajna.

Prilikom provođenja testa razmjernosti Službenik za informiranje sagledao je predmetni zahtjev u širem kontekstu stavljajući pritom u odnos zakonsku obvezu Agencije na čuvanje poslovne tajne s motivom podnošenja predmetnog zahtjeva za pristup informacijama, a sve u svrhu utvrđivanja koji interes prevladava u konkretnom slučaju.

Službenik za informiranje smatra kako omogućavanjem pristupa traženim informacijama ne bi prevladao javni interes u odnosu na počinjenu štetu dostavljanjem informacija koje su zaštićene posebnim propisom kao poslovna tajna, a pogotovo imajući u vidu kako je motiv pribavljanja podataka Podnositeljice zahtjeva izrada doktorske disertacije, koja predstavlja privatni interes pojedinca. Shodno tomu, Službenik za informiranje upućuje podnositeljicu da se u izradi svoje disertacije usmjeri na objavljene odluke Agencije i priopćenja vezana uz takve odluke kao i da potrebne podatke pokuša prikupiti od sektorskog regulatora kao i od samih poduzetnika koji djeluju na predmetnom tržištu.

Službenik za informiranje je utvrdio kako se konkretnim zahtjevom traži pristup neutvrđenom broju informacija i to onima kojima je pristup onemogućen izričitom zakonskom odredbom, kojom su te informacije utvrđene kao poslovna tajna, te da prevladava potreba zaštite prava na ograničenje, a ne javni interes. Dakle, Službenik za informiranje utvrdio je kako bi omogućavanjem pristupa traženoj informaciji zaštićeni interes, odnosno tajnost podataka, bio povrijeđen, te da stoga prevladava potreba zaštite prava na ograničenje.

Dakle, sukladno prethodno navedenom, Službenik za informiranje riješio je kako se pristup traženim informacijama u konkretnom slučaju može ograničiti radi zaštite zaštićenog interesa iz članka 15. stavka 2. točke 2. ZPPI.

Slijedom navedenog, odlučeno je kao u Izreci ovog rješenja.

Uputa o pravnom lijeku:
Protiv ovog Rješenja korisnik ima pravo izjaviti žalbu Povjereniku za informiranje u roku od 15 dana od dana dostave rješenja.

Službenik za informiranje

Branka E[illegible] mag.iur.univ.spec.oec.

Prilog 2.: Rezultati dijagnostike procijenjenih VAR sustava

Hipoteza	Pokazatelj cijena nafte	Autokorelacija[199]	Heteroskedastičnost[200]	Normalnost[201]	Stabilnost modela[202]
H1	DLOIL	23,83	207,59***	928,37***	DA
	MORK+/MORK-	31,28	1152,56	483,88***	DA
	SOPI/SOPD	26,08	333,75***	2442,41***	DA
	NOPI4	21,31	207,95**	346,19***	DA
H2	DLOIL	33,49	1310,05***	439,82***	DA
	MORK+/MORK-	57,85	2322,00***	542,49***	DA
	SOPI/SOPD	55,81	1712,18**	696,67***	DA
	NOPI4	35,53	1374,47***	586,43***	DA
H3	DLOIL	15,89	385,94**	339,91***	DA
	MORK+/MORK-	21,33	978,05*	342,96***	DA
	SOPI/SOPD	28,76	461,55	504,63***	DA
	NOPI4	16,42	290,56**	609,88***	DA
H4	DLOIL	17,21	554,15	15,62**	DA
	MORK+/MORK-	30,01	458,16**	33,39***	DA
	SOPI/SOPD	24,82	360,30*	207,54***	DA
	NOPI4	10,47	274,80	14,80**	DA
H5	DLOIL	22,48	572,69	17,50**	DA
	MORK+/MORK-	26,65	1079,31	29,35***	DA
	SOPI/SOPD	17,09	953,29	153,96***	DA
	NOPI4	19,19	620,80*	18,81**	DA

*, **, *** indicira statistički značajan rezultat na razini od, redoslijedno: 10%, 5% i 1%
Izvor: Izračun autorice

[199] LM test veličina posljednjeg vremenskog odmaka uključenog u model uz zadovoljen uvjet nepostojanja autokorelacije u prethodnim vremenskim odmacima
[200] Test veličina White testa
[201] Jarque-Bera test veličina
[202] DA implicira da se niti jedan korijen karakteristične jednadžbe ne nalazi izvan jediničnog kruga (po Euklidovoj normi)

ŽIVOTOPIS

Marina Lolić Čipčić rođena je 19.03.1984. u Splitu. U Splitu je pohađala II jezičnu gimnaziju od 1998. do 2002. godine nakon čega upisuje Ekonomski fakultet Sveučilišta u Splitu. Diplomirala je 2006. godine, usmjerenje Međunarodna ekonomija i financije, uz počasti *summa cum laude*. Iste godine nagrađena je i od strane tvrtke Konstruktor d.o.o. priznanjem i novčanom nagradom za uspješne studente.

U srpnju 2007. godine zapošljava se na Sveučilištu u Splitu, Sveučilišnom odjelu za stručne studije, kao asistent. U nastavno zvanje predavača birana je 2012. godine, a 2017. u nastavno zvanje višeg predavača. Na Sveučilišnom odjelu za stručne studije sudjeluje u izvođenju nastave na preddiplomskom stručnom i specijalističkom diplomskom stručnom studiju Menadžment trgovine i turizma gdje je nositeljica predmeta Osnove ekonomije, Poslovna ekonomija, Gospodarstvo Republike Hrvatske i Međunarodna ekonomija. Područja znanstvenog interesa uključuju mikroekonomiju, makroekonomiju i ekonomiku energetike. Od akademske godine 2016./2017. na Odjelu za stručne studije obnaša funkciju zamjenice pročelnika Odjela za nastavu i međunarodnu suradnju.

POPIS RADOVA:

- Lolić Čipčić, M. (2019), *Analysis of the Labour Market in Croatia*, 49th International Scientific Conference on Economic and Social Development, Book of Proceedings, Editors: Dukic et al., ISSN 1849-7535, Zagreb, 13-14 December 2019, str. 371-380

- Pavić Kramarić, T., Lolić Čipčić, M., Miletić, M. (2017), *Has the Financial Crisis Affected the Profitability of Banks in Croatia?*, Journal of Applied Finance & Banking, 2017, Volume 7 - Issue 3, str. 21-45

- Lolić Čipčić, M., Pavić Kramarić, T., Miletić, M. (2017), *Do oil prices affect croatian stock market?*, 6th International scientific symposium Economy of eastern croatia – Vision and growth, Osijek, 25th – 27th May 2017, Book of proceedings, ISSN 1848-9559, str. 1083-1093

- Pavić Kramarić, T., Miletić, M., Lolić Čipčić, M. (2017), *Growth prospects and claims ratio as triggers of mergers&acquisitions in Polish insurance market,* 23rd International Scientific Conference on Economic and Social Development, Book of Proceedings, Editors: Cingula et al., ISSN 1849-7535, Madrid, 15-16 September 2017, str. 253-263

- Pavić Kramarić, T., Lolić Čipčić, M. (2016), *Management and supervisory board gender diversity as an indicator of banks' and insurance companies' profitability in Croatia*, Proceedings of the 2nd International Conference Contemporary Issues in Economy & Technology, CIET 2016, Split, 16-18 June 2016 (ISBN 978-953-7220-25-9, Scientific paper, S – 22-32)

- Lolić Čipčić, M.(2014), *What Drives Crude Oil Prices?*, Proceedings of the 4th International Conference „Vallis Aurea" Focus on: Regional & Innovation Development, Polytechnic in Požega, (ISBN 978-3-902734-02-0, ISSN 1847-8204), Požega, Hrvatska, 18-20 rujan, 2014.

- Lolić Čipčić, M., Zečević, A. (2014), *Analiza koncentracije tržišta osiguranja u Republici Hrvatskoj*, Proceedings of the 1st International Conference Contemporary Issues in Economy & Technology, CIET 2014, Split, 19-21 June 2014 (ISBN 978-953-7220-15-0, Professional paper, P – 254-265)

- Lolić Čipčić M. (2014), *Cijene nafte i tržište naftnih derivata u Europskoj Uniji*, Proceedings of the 1st International Conference Contemporary Issues in Economy & Technology, CIET 2014, Split, 19-21 June 2014 (ISBN 978-953-7220-15-0, Professional paper, P – 266-278)

- Lolić Čipčić, M. (2012), *Energy Prices And Social Policy: Tackling Energy Poverty In Europe*, Proceedings of the 3rd International Conference „Vallis Aurea" Focus on: Regional Development, Polytechnic in Požega, (ISBN 978-953-7744-16-8, ISBN 978-3-901509-78-0, ISSN 1847-8204), Požega, Croatia, 5th October, 2012

- Akrap, I.; Miletić, M.; Lolić Čipčić, M. (2010), *Legal Organization of Interests and Interests Accounting Methods*, 2nd International Conference "Vallis Aurea - Focus On: Regional Development", Veleučilište u Požegi, Hrvatska i Daaam International Vienna, Austrija, Požega, Hrvatska, 03. rujan 2010.

- Lolić Čipčić, M., Vasilj, M., Akrap, I. (2010), *EU Energy Prospects - Common Energy Policy?*, 2nd International Conference "Vallis Aurea - Focus On: Regional Development", Veleučilište u Požegi, Hrvatska i Daaam International Vienna, Austrija, Požega, Hrvatska, 03. rujan 2010.

- Vidović J., Miletić M., Lolić Čipčić M. (2009), *Dividend Annoucement Effect – Evidence From Croatia*, "UN Millenium Developmnet Goals: Challenges And Prespectives", Szent Istvan University of Godollo, Godollo Mađarska, 23.-26. lipanj 2009.

- Lolić M., Vidović J. (2008), *Renewable Energy Sources as Potential of Croatian Energy Sector Development*, 1st International Conference "Vallis Aurea - Focus On: Regional Development", Veleučilište U Požegi, Hrvatska i Daaam International Vienna, Austrija, Požega, Hrvatska, 19. rujan 2008.