UNIVERZITET CRNE GORE
EKONOMSKI FAKULTET PODGORICA

Tanja Mirotić

MAKROEKONOMSKI MODEL FILIPSOVE KRIVE – STUDIJA SLUČAJA CRNA GORA

MASTER RAD

Podgorica, 2022. godina

PODACI I INFORMACIJE O STUDENTU

Ime i prezime:	Tanja Mirotić
Datum i mjesto rođenja:	13.11.1994. godine, Podgorica
Naziv završenog osnovnog studijskog: programa i godina završetka studija:	Ekonomski fakultet, smjer „Kvantitativna ekonomija“, 2017. godina

INFORMACIJE O MASTER RADU

Naziv postdiplomskog studija:	Ekonomski fakultet Podgorica, Magistarske studije, smjer „Kvantitativna ekonomija“
Naslov rada:	„Makroekonomski model Filipsove krive – studija slučaja Crna Gora"

OCJENA I ODBRANA MASTER RADA

Datum prijave master rada:	05.07.2018. godine
Datum sjednice Vijeća univerzitetske jedinice na kojoj je prihvaćena tema:	19.11.2018. godine
Mentor:	Prof. dr Vesna Karadžić
Komisija za ocjenu rada:	1. Prof. dr Vesna Karadžić 2. Prof. dr Svetlana Rakočević 3. Doc. dr Zdenka Dragašević
Komisija za odbranu rada:	1. Prof. dr Vesna Karadžić 2. Prof. dr Svetlana Rakočević 3. Doc. dr Zdenka Dragašević
Datum odbrane:	
Datum promocije:	

IZJAVA O POTVRĐIVANJU ORIGINALNOSTI MASTER RADA
(u skladu sa čl. 22. Zakona o akademskom integritetu)

Potpisana/i: Tanja Mirotić

(ime i prezime)

Broj indeksa: 20/17

Izjavljujem

pod krivičnom i materijalnom odgovornošću da je master rad pod naslovom:

Makroekonomski model Filipsove krive – studija slučaja Crna Gora

moje originalno djelo.

U Podgorici, 27.06.2022. Svojeručni potpis,

Predgovor

Zabilježena hiperinflacija u Saveznoj Republici Jugoslaviji (SRJ), krajem 1993. godine i početkom 1994. godine, dovela je zemlju u poziciju da u potpunosti obezvrijedi sopstvenu valutu i praktično dovede do gubitka iste. Zahvaljujući vođenju takozvane akomodirajuće politike, Narodna banka Jugoslavije (NBJ) je konstantno štampala novac i povećavala njegov opticaj na tržištu, što je djelovalo razarajuće na privredu cijele zemlje. Nezadovoljstvo ljudi je raslo, redovi isped prodavnica od ranih jutarnji časova za veknu hljeba su bili ogromni, a pravo rješenje nije nađeno. Inflacija iz tog perioda ostavila je posljedice na ekonomiju Crne Gore, dok je istovremeno zadala težak zadatak kreatorima ekonomske politike da se s istom izbore na najoptimalniji mogući način za date uslove. Zbog negativnog iskustva koje je inflacija izazvala ona se, zajedno s nezaposlenošću, tretira kao veliki makroekonomski problem u zemljama bivše Jugoslavije.

Crna Gora kao zemlja u tranziciji, prolazeći kroz čitav proces privatizacije, smanjila je obim privredne aktivnosti što je dovelo do rasta nezaposlenosti. Na takvu situaciju dodatno je uticala i nerazvijenost privatnog sektora, koji nije mogao podržati dovoljan rast zaposlenosti kako bi se kriza prevazišla. Iz tog razloga povećanje nivoa zaposlenosti se ističe kao važan makroekonomski cilj, koji teži da se maksimizira. Izgleda da kako smo prošli period inflacije i izborili se s njim, isplivala je nezaposlenost, pa se postavlja uzročno-posljedično pitanje, koje predstavlja enigmu dugi niz godina, a to je: „Da li boreći se za suzbijanje inflacije zapravo izazivamo nezaposlenost?”

Inverzan odnos inflacije i nezaposlenosti je istorijski predstavljen kroz makroekonomski model Filipsove krive, koji će u ovom radu biti analiziran na realnim podacima i na primjeru crnogorske privrede. U radu su formulisane dvije hipoteze. Prvom hipotezom se želi utvrditi da li je teorijski koncept Filipsove krive, testiran na empirijskim podacima, relevantan za ekonomiju Crne Gore, dok se drugom hipotezom želi utvrditi da li model Filipsove krive daje validnu prognozu stope inflacije u Crnoj Gori. Validnost i mogućnost predviđanja pomoću ovog modela bi, kreatorima makroekonomske politike, olakšali proces donošenja važnih makroekonomskih odluka, što bi dovelo do blagostanja, kako pojedinaca tako i društva u cjelini.

Izvod rada

Ekonomiju, kao kompleksnu društvenu nauku, karakteriše postojanje velikog broja varijabli, pa i ne čudi postojanje mogućnosti kombinacija tih istih varijabli radi formiranja modela koji mogu poslužiti za kreiranje ekonomske politike jedne zemlje. U ovom radu će biti testirana validnost makroekonomskog modela Filipsove krive u Crnoj Gori, na osnovu empirijskih podataka o stopi nezaposlenosti i stopi inflacije, koji su preuzeti sa sajta Centralne banke Crne Gore.

Nasuprot bogate svjetske literature, gdje postoji veliki broj naučnih radova čija je glavna tema upravo Filipsova kriva i njeno dokazivanje na empirijskim podacima, u Crnoj Gori se još uvijek niko nije bavio istraživanjem ovog fenomena. Ova činjenica istraživački problem čini još interesantnijim pa je, izmedju ostalog, to i jedan od glavnih motiva za izučavanje ovog modela. Osim toga, kao bitni razlozi za odabir upravo ove teme za istraživanje su i: analitička jednostavnost modela Filipsove krive, primjenljivosti u ekonomskoj politici, velike mogućnosti za empirijsku provjeru modela, ali i njena sve veća upotreba u okviru drugih teorijskih koncepata kao što su teorija blagostanja, teorija igara, zatim njena primjena u međunarodnoj koordinaciji ekonomske politike, što joj daje na još većem značaju.

Rad je koncipiran tako da se sastoji iz tri ključna dijela. Nakon uvoda, u prvom dijelu rada, razjašnjenja je teorijska osnova Filipsove krive, nastanak ideje o inverznom odnosu inflacije i nezaposlenosti i njen razvoj i modifikacija kroz uticaj brojnih ekonomskih politika koje su se tokom vremena mijenjale. Dat je osvrt na objašnjenje kratkoročne i dugoročne Filipsove krive kao i na otvorena pitanja u vezi Filipsove krive. U drugom dijelu su objašnjeni osnovni principi ekonometrijskog modeliranja, koji služe kao osnova za formiranje ekonometrijskog modela. Treći dio sadrži empirijsku analizu ekonometrijskog modela Filipsove krive u Crnoj Gori. Na kraju, dat je zaključak, koji je donesen na osnovu teorijskog i empirijskog istraživanja, i pregled korišćene literature.

Standardne ekonometrijske metode pomogle su u formiranju jednostavnog ekonometrijskog modela, na osnovu kojeg je ispitana veza izmedju stope inflacije i stope nezaposlenosi, koristeći softverski program EViews. Rezultati testova su pokazali da model nije valjan za crnogorsko tržište, pa pomoću njega nije moguće vršiti predviđanje.

Ključne riječi: inflacija, nezaposlenost, Filipsova kriva, kriza, ekonometrijski model, vremenske serije.

Abstract

Economics, as a complex social science, is characterized by the existence of a large number of variables, so it is not surprising that there is possibility of combining these same variables to form models that can serve to conduct economic policy of a country. This paper will test the validity of the macroeconomic model of the Phillips curve in Montenegro, based on empirical data on the unemployment rate and inflation rate, taken from the website of the Central Bank of Montenegro.

Contrary to the rich world literature, where there is a large number of scientific papers whose main topic is precisely Phillips' curve and its proving on empirical data, no one in Montenegro has yet researched this phenomenon. This fact makes the research problem even more interesting, so among other things, it is one of the main motives for studying this model. In addition, the important reasons for choosing this research topic are: analytical simplicity of the Phillips curve model, applicability in economic policy, great possibilities for empirical verification of the model, but also its increasing use in other theoretical concepts such as welfare theory, game theory, then its application in the international coordination of economic policy, which gives it even more importance.

The paper is designed to consist of three key parts. After the introduction, in the first part of the paper, the theoretical basis of the Phillips curve is clarified, the idea of the inverse relationship between inflation and unemployment, its development and modification through the influence of numerous economic policies that have changed over time. The explanation of the short-term and long-term Phillips curve as well as the open questions regarding the Phillips curve are given. The second part explains the basic principles of econometric modeling, which serve as the basis for the formation of the econometric model. The third part contains an empirical analysis of the econometric model of the Phillips curve in Montenegro. Finally, a conclusion, made based on theoretical and empirical research, and an review of the literature used.

Standard econometric methods helped to form a simple econometric model, which examined the relationship between the inflation rate and the unemployment rate, using the software program EViews. The test results showed that the model is not valid for the Montenegrin market and therefore it is not possible to make predictions with it.

Keywords: inflation, unemployment, Phillips curve, crisis, econometric model, time series.

Sadržaj

UVOD 9
1. FILIPSOVA KRIVA – TEORIJSKI OKVIR 10
1.1. Rana istorija razvoja Filipsove krive – začetak ideje 10
1.1.1. Prototip Filipsove krive – *David Hume* 11
1.1.2. Filipsova kriva u devetnaestom vijeku – *Attwood–Mill* debata 13
1.1.3. „Ja sam otkrio Filipsovu krivu“ – *Irving Fisher* 14
1.2. Standardna Filipsova kriva 16
1.3. Filipsova kriva sa adaptivnim očekivanjima 18
1.4. Filipsova kriva sa racionalnim očekivanjima 21
1.5. Otvorena pitanja u vezi sa Filipsovom krivom 22
1.5.1. Istovremeni porast inflacije i nezaposlenosti – stagflacija 23
1.5.2. Okunov zakon – empirijska veza između zaposlenosti i bruto društvenog proizvoda 24
2. OSNOVNI PRINCIPI EKONOMETRIJSKOG MODELIRANJA 26
2.1. Osnovni koncepti analize vremenskih serija 27
2.1.1. Ispitivanje uslova normalnosti 30
2.1.2. Testiranje stacionarnosti 32
2.1.3. Koncept kointegracije 34
2.2. Konstruisanje linearnog regresionog modela 35
2.2.1. Specifikacija modela 35
2.2.3. Ocjena modela i vrednovanje ocjene modela 37
2.2.4. Izbor odgovarajućeg modela 42
2.3. Predviđanje linearnim regresionim modelom 43
3. EMPIRIJSKA ANALIZA EKONOMETRIJSKOG MODELA FILIPSOVE KRIVE U CRNOJ GORI 44
3.1. Grafički prikaz i deskriptivna statistika 44
3.2. Ispitivanje stacionarnosti vremenskih serija 48
3.3. Specifikacija modela Filipsove krive u Crnoj Gori 52
3.3.1. Ramsey Reset Test 58
3.3.2. Redundant Variable Test 64
3.3.3. Jarque-Bera Test 66
3.3.4. Granger Causality Test 67
3.4. Ocjena i vrednovanje modela Filipsove krive u Crnoj Gori 68
3.4.1. Ispitivanje autokorelacije: Breusch-Godfrey Serial Correlation LM Test 69

3.4.2. Ispitivanje heteroskedastičnosti: Glejser test 69
3.4.3. Multikolinearnost 71
3.5. Finalna interpretacija rezultata 74
ZAKLJUČAK 77
LITERATURA 79
DODATAK 83

UVOD

Koncept Filipsove krive datira još iz 1958. godine, kada je *A. W. Philips* dokazao inverzan odnos između stope nezaposlenosti i stope promjene novčanih nadnica na primjeru Velike Britanije. Nakon toga se veliki broj istaknutih ekonomista, kao što su *Solow, Samuelson, Friedman, Lipsey* i drugi, bavio istraživanjem ovog fenomena, koji je i danas relevantna tema. Kao dokaz aktuelnosti ovog teorijskog koncepta jeste i činjenica da ne postoji udžbenik iz oblasti makroekonomije, pa ni monetarne ekonomije, a da u svoj sadržaj ne uključuje Filipsovu krivu. Tokom 60-tih i 70-tih godina XX vijeka Filipsova kriva je predstavljala popularan instrument ekonomske politike. Iako tokom perioda stagflacije i šokova agregatne ponude, inverzan odnos između stope inflacije i stope nezaposlenosti nije postojao, događaji tokom 80-tih i 90-tih godina kao i kriza 2008. godine, aktuelizovali su ponovna razmatranja ovog teorijskog koncepta.

S obzirom na to da je pojavljivanje i nestajanje inverznog odnosa između stope inflacije i stope nezaposlenosti nemoguće predvidjeti, sprovode se konstantna empirijska istraživanja koja testiraju validnost Filipsove krive u savremenim privredama. Svrha ovog rada je formulisanje odgovarajućeg modela Filipsove krive za Crnu Goru i njegova ocjena na empirijskim podacima koji su preuzeti sa sajta Centralne banke Crne Gore. Tema dobija još više na značaju jer se u Crnoj Gori niko nije bavio empirijskim dokazivanjem postojanja Filipsove krive, pa se u tome i ogleda glavni naučni doprinos ovog rada. Takođe, u istraživanju je sprovedeno testiranje validnosti modela primjenom odgovarajućih statističkih i ekonometrijskih testova i upotrebom softverskog paketa EViews 7.

Cilj istraživanja je da se na osnovu teorijskih saznanja i empirijskih podataka testira relevantnost modela Filipsove krive u crnogorskoj privredi i izvrši predviđanje stope inflacije na osnovu ocijenjenog modela. Suština teorijskog dijela istraživanja je proučavanje postojeće, dostupne literature i internet sajtova sa ciljem što boljeg razumijevanja značaja teorijskog koncepta Filipsove krive, koji povezuje makroekonomske pokazatelje, stopu inflacije i stopu nezaposlenosti. Primjena empirijskog istraživanja ogleda se u testiranju hipoteza i izvođenju zaključaka na osnovu realnih podataka vremenskih serija stope inflacije i stope nezaposlenosti.

Zadatak rada je da utvrdi kakav je odnos između stope inflacije i stope nezaposlenosti u Crnoj Gori, kao i da li je moguće njihov međusobni uticaj iskoristiti za kreiranje budućih ekonomskih odluka u oblasti makroekonomije naše zemlje, pa samim tim i da podstakne kritičko razmišljanje čitalaca o obrađenoj temi.

1. FILIPSOVA KRIVA – TEORIJSKI OKVIR

"Čini se da je svako vrijeme pravo vrijeme za razmišljanje o Filipsovoj krivoj"
Robert M. Solow (1976)

U ovom poglavlju će biti objašnjen teorijski okvir modela Filipsove krive kao i osnovna relacija na kojoj model počiva, a to je inverzni odnos između dva značajna makroekonomska indikatora, stope inflacije i stope nezaposlenosti. Hronološki posmatrano, etape u razvoju Filipsove krive su, u radu, podijeljene na tri perioda:

Vremenski period prije 1958. godine, obuhvata period začetka ideje o inverznom odnosu između inflacije i nezaposlenosti i zato zauzima izuzetno važno mjesto u razvoju ekonomske misli, pa mu je posvećeno posebno poglavlje. (***Poglavlje 1.1. - Rana istorija razvoja Filipsove krive - začetak ideje***)

Godina 1958., kada je *Philips* objavio svoj rad *„The relation between unemployment and the rate of change of money wage rates in the United Kingdom, 1861.-1957.",* ova godina se vezuje za nastanak originalne Filipsove krive. (***Poglavlje 1.2. - Standardna Filipsova kriva***)

Vremenski period nakon 1958. godine, obilježen burnim ekonomskim promjenama, obiluje velikim brojem teorija, diskusija, debata ali i ekonometrijskih radova, koji su zaslužni što je Filipsova kriva prošla kroz četiri faze, kojima su posvećena posebna poglavlja. (***Poglavlje 1.2., 1.3., 1.4.)***. Takođe, kroz ova poglavlja će biti istaknut značaj Filipsove krive u kreiranju ekonomskih politika pomoću formiranja očekivanja, dok će u posljednjem poglavlju ***(Poglavlje 1.5.)*** biti istaknuta otvorena pitanja u vezi sa Filipsovom krivom koja će čitaocu pomoći da bolje razumije značaj istraživanja ovog fenomena.

1.1. Rana istorija razvoja Filipsove krive – začetak ideje

Iako je većina kritičara smatrala neprimjerenom empirijsku vezu koja je predstavljena kao *tradeoff* između inflacije i nezaposlenosti, ipak je Filipsova kriva bila, a i dalje ostala jedan od ključnih makroekonomskih modela u posljednjih sedamdeset godina. Naziv Filipsova kriva je dobila 1960. godine, kada su *Paul Samuelson* i *Robert Solow* odlučili da inverzan odnos između inflacije i nezaposlenosti nazovu po *A. W. Philips*-u, novozelandskom ekonomisti, koji je 1958. godine dao do tada najbolju formulaciju modela, ali ne prvu i jedinu.

Ono što nije toliko poznato kada je u pitanju razvoj ideje o inverznom odnosu inflacije i nezaposlenosti, i što većina udžbenika makroekonomije ne obrađuje u svojim poglavljima, jesu verzije modela koje su opisivale isti odnos, a javile su se mnogo ranije od modela „zvanične" Filipsove krive. Iz tog razloga, važno je istaći značaj ekonomista koji su se bavili ovom temom prije *A. W. Philips*-a i na taj način doprinijeli razvoju ekonomske nauke u velikoj mjeri. Jedan od njih je *John Law (1671 – 1729)*, škotski ekonomista, bankar i ministar finansija čija je glavna ideja bila da je ekonomski razvoj moguć uz pomoć papirne valute čije bi pokriće bilo u srebru i zlatu. Njegova teorija o monetarnoj politici, moći papirnog novca kao kredita i važnosti postojanja

centralizovane banke, koja bi se bavila novim oblikom papirnog novca, je bila ispred svog vremena.[1] Međutim, zastupao je merkantilistička uvjerenja kada je u pitanju ekonomski interes države, podržavajući veću državnu intervenciju, zabranu uvoza i povećanje izvoza. Vjerovao je da novac stimuliše privrednu aktivnost, ali da se to dešava pri konstantnim ili čak opadajućim cijenama. Kao rezultat, odnos između inflacije i nezaposlenosti ili ne postoji ili je pad nezaposlenosti povezan sa padom a ne rastom cijena, što je zapravo suprotno od empirijskih dokaza koji su isplivali u godinama koje slijede.

1.1.1. Prototip Filipsove krive – *David Hume*

David Hume (1711 – 1776), škotski filozof i ekonomista, pisao je o politici, istoriji i ekonomiji. Razvio je kvantitativnu teoriju novca, u kojoj ističe da količina novca ima direktan, proporcionalan odnos sa nivoom cijena.[2] Od dvanaest eseja koji su prvi put objavljeni 1752. godine, u knjizi *„Politički diskursi“*, sedam je posvetio ekonomskim temama, kao što su: trgovina, inflacija, novac, privatno vlasništvo.[3]

D. Hume je prvi opisao osnov na kojem se zasniva Filipsova kriva, i to u obliku jednakosti: U=g(Dp/dt), gdje U predstavlja odstupanje nezaposlenosti od svoje prirodne stope, dok je dP/dt promjena nivoa cijena u odnosu na vrijeme. Ovu relaciju je izveo iz pretpostavke da promjene nezaposlenosti proizilaze iz pogrešne procjene cijena, kao i da takve procjene perzistiraju jedino u situacijama kad su cijene promjenljive. Ovakav odnos nezaposlenosti i inflacije potvrđuje njegovu hipotezu da, ukoliko se želi održati nizak nivo nezaposlenosti, rast cijena mora biti kontinuiran.

Hume-ov esej pod nazivom *„Of Money“* jedan je od radova koji je ostavio veliki uticaj na buduće ekonomiste, koji su ga posmatrali kao izvor ideja i preteču monetarista. Jedan od njegovih stavova je da je na dugi rok novac neutralan. Za njega je novac samo obračunska jedinica, i ne igra važnu ulogu u stimulisanju ekonomske aktivnosti. Jasno je definisao razliku između realne i nominalne količine novca, koja je kod monetarista posebno naglašena. U svom eseju *„Of Money“ Hume* kaže: „Ako posmatramo bilo koje kraljevstvo samo po sebi, očigledno je da veća ili manja količina novca nije od značaja; pošto su cijene roba uvijek proporcionalne količini novca...Maksima je gotovo sama po sebi razumljiva, da cijene svega zavise od odnosa roba i novca, i da svaka značajna izmjena na bilo kom od njih ima isti efekat, povećanje ili smanjenje cijena…Sva povećanja (zlata

[1] Banka, čiji je osnivač *John Law,* pod nazivom *Banque Générale,* formirana je u cilju oporavka finansijske situacije u Francuskoj. *Law* je smatrao da je glavni problem Francuske to što je ponuda srebra i zlata nepredvidljiva, pa je usred toga trgovina otežana, a najbolje rješenje za prevazilaženje takve situacije je zamjena srebra i zlata papirnim novcem. Ubrzo je postavljen na čelo *Mississippi Company*, koja je tada imala monopol u državi, i cijene akcija kompanije su počele naglo da rastu. Međutim, investitori su ipak željeli zarade u zlatu i srebru, što je bilo suprotno njegovim očekivanjima. Pokušao je da popravi situaciju uvođenjem djelimične isplate u zlatu i srebru, a francuski franak je vezao za akcije u *Mississippi Company*. Takav potez je 1720. godine doveo do “pucanja” špekulativnog mjehura, poznatog pod nazivom “*Mississippi Bubble”.*

[2] Klasična ekonomska škola, čiji je najznačajniji predstavnik *Adam Smith,* je evoluirala u dva pravca: kvantitativna teorija novca (*David Hume*) i teorija opšte ravnoteže (*Léon Walras*).

[3] Nakon šest godina objavljen je i trinaesti esej pod nazivom „*Of the Jealousy of trade*”.

i srebra) nemaju drugog efekta osim povećanja cijena roba i rada. Novac nije, pravilno govoreći, jedan od predmeta trgovine, već samo instrument oko kojeg su se ljudi dogovorili da bi olakšali razmjenu jedne robe za drugu.“[4]

Smatrao je da bi povećanje ponude novca dovelo do viših cijena usljed povećanja rashoda. Kao rezultat toga, izvoz bi postao manje konkurentan dok bi uvoz postao „jeftin”. Shodno tome, u bilansu plaćanja bi se pojavio deficit, što bi izazvalo povratak količine novca na svoj prethodni nivo. Na ovaj način on je postao prvi koji je primijenio monetarističku teoriju u otvorenoj ekonomiji.

Međutim, *Hume* je imao interesantan stav kada je u pitanju inflacija. Naime, nije mogao da prepozna velike gubitke koje inflacija nosi sa sobom i smatrao je da je izuzetno važna u pokretanju ekonomske aktivnosti. Inverzan odnos postoji, između nezaposlenosti i neopaženih promjena u novcu i cijenama, u trenutku kada se očekivanja u potpunosti prilagode stvarnosti. Iako se percepcije o cijenama sporo prilagođavaju, ipak će u jednom trenutku da se poklope sa nivoom cijena, što bi značilo da takve promjene najbolje pokazuju da je *tradeoff* privremen, a ne stalan. Takođe, jedini način da se *tradeoff* održi je omogućavanje konstantnih sukcesivnih promjena u novcu i cijenama. *Hume* je, na osnovu argumenta o neracionalnim očekivanjima, smatrao da će takve promjene, zbog kašnjenja u prilagođavanju očekivanim cijenama, ostaviti cijene da uvijek budu ispred očekivanja. Na ovaj će način razlika između stvarnih i očekivanih cijena biti održavana, pri čemu će to uticati na smanjenje nezaposlenosti (važi i obrnuto, ukoliko deflacija duže traje izazvaće porast nezaposlenosti). Na osnovu ovoga, proizilazi da je *Hume* vjerovao u stabilnu, dugoročnu Filipsovu krivu, koja prikazuje inverzan odnos između nezaposlenosti i stope promjene cijena.

Henry Thornton (1760 – 1815) je engleski ekonomista koji je na isti način kao i *Hume* opisao relaciju između nezaposlenosti i inflacije. *Thornton* je smatrao da inflacija stimuliše ekonomsku aktivnost, i to smanjenjem realnih plata i povećanjem realnih profita. Na ovaj način se povećava preraspodjela jer plate kasne za cijenama i to kašnjenje perzistira dok god se inflacija održava. Nije istakao svoje stavove o inflatornim očekivanjima, niti ih je inkorporisao u „svojoj” Filipsovoj krivoj. Međutim, nije se usaglasio sa *Hume*-om kada je u pitanju upotreba Filipsove krive u kreiranju ekonomske politike. Dok je *Hume* vjerovao da vlast, u zatvorenoj ekonomiji, treba da iskoristi Filipsovu krivu da stimuliše zapošljavanje, *Thornton* smatra da su pozitivni efekti inflacije beznačajni u odnosu na štetu koju ona može da nanese.[5]

[4] David Hume, *Political Discourses*, 1752, p. 41.
[5] Humphrey, T.M., *The Early History of the Philips Curve,* Economic Review, Vol. 71, no. 5, September/October 1985, p. 19.

1.1.2. Filipsova kriva u devetnaestom vijeku – *Attwood–Mill* debata

U devetnaestom vijeku, nakon *Hume*-a i *Thornton*-a, *Thomas Attwood (1783 – 1856)*[6], bankar iz Birmingema, prepoznao je inverzan odnos između inflacije i nezaposlenosti. Bio je zagovornik inflatorne politike, režima nekonvertibilne papirne valute i pune zaposlenosti po svaku cijenu. Vjerovao u stabilni, dugoročni i inverzni odnos nezaposlenosti i nivoa cijena, koristeći relaciju: U=g(P), gdje U predstavlja nezaposlenost, a P nivo cijena. Ovom relacijom *Attwood* tvrdi da visoka nezaposlenost proizilazi iz niskih cijena, da niska nezaposlenost proizilazi iz visokog nivoa cijena i da vlada može i treba da postigne nultu stopu nezaposlenosti sa inflatornom monetarnom ekspanzijom. Smatrao je da treba obnoviti depresirano stanje valute jer će država na taj način omogućiti sopstveni prosperitet.[7]

Attwood-ov cilj je bila puna zaposlenost. Njegov kauzalni model je jednostavan. Deflatorna politika usmjerena na smanjenje cijena (posebno smanjenje javnih ratnih rashoda) zaustavlja proizvodnju i iscrpljuje zalihe.[8]

Nasuprot *Attwood*-u, svoju teoriju je razvijao filozof i ekonomista, *John Stuart Mill (1806 – 1873)*, kao jedan od značajnijih predstavnika klasične škole. Na polju filozofije bio je pod uticajem Bentamovog utilitarizma, dok je na polju ekonomije zagovarao Rikardovu teoriju, koju je pokušao da sistematizuje, tumači i propagira. On, na veoma pregledan način, u svom stvaralaštvu izlaže skoro sve ideje klasične škole, ali ističući i veliki broj vlastitih stavova. Zbog niza pozitivnih shvatanja koje je imao za mnoge probleme ekonomske teorije i položaj radničke klase, sa pravom bi se mogao nazvati i klasičnim liberalom, tj. glavnim ideologom liberalnog reformizma.[9]

Umjesto *Attwood*-ove relacije U=g(P), *Mill* je zastupao da je $U=g(P-P^E)$, gdje je U nezaposlenost koja je predstavljena razlikom između nivoa cijena (P) i očekivanog nivoa cijena (P^E). Ovom relacijom, *Mill* je tvrdio da je inverzan odnos između nezaposlenosti i inflacije privremen i nestaje u trenutku kada se očekivanja prilagode stvarnosti. Takođe, suprotno *Attwood*-u[10], smatrao je da ne postoji mogućnost da se realna aktivnost u privredi dovede na niski nivo

---

[6] Na *Attwood*-ovo razmišljanje značajno su uticali efekti deflacione strategije Banke Engleske, nakon Napoleonovih ratova, čiji je cilj bio da obnove plaćanje u metalnom (kovanom) novcu (zlatnici i srebrenjaci). Postao je centralna ličnost u protivljenju pokušajima Banke Engleske da vrati novčanice u paritet sa zlatom na uštrb ekonomske aktivnosti.
[7] Attwood, Thomas. The Remedy; or, Thoughts on the Present Distresses. Second edition, with additions. London : 1816., p. 66.
[8] Attwood, Thomas. The Remedy; or, Thoughts on the Present Distresses. Second edition, with additions. London : 1816., p. 59.
[9] Rakčević-Glišević, N., Razvoj i osnove savremene ekonomske misli", Podgorica, 2004, str. 137-138.
[10] *Mill* je zastupnik zlatnog standarda i snažno je kritikovao *Attwood*-a u svom članku *"The Currency Juggle"* (1833). Posebno ga je kritikovao kad je u pitanju zapošljavanje. Tvrdio je da čak i ako bi inflacija mogla da stimuliše privredu, takav podsticaj je nepoželjan u smislu njegovih efekata na efikasnost i pravičnost. Smatrao je da treba voditi monetarnu politiku zasnovanu na pravilima. Njegova analiza ovih pitanja je moderna i ispred svog vremena. Zbog kritika koje je upućivao na račun *Attwood*-ovih stavova, po pitanju ekonomskih tema, često se u literaturi mogu naći naslovi "*Attwood-Mill* debata".

jednostavnim prilagođavanjem nominalnih cijena (inflacije), jer su ove dvije varijable zapravo nezavisne jedna od druge, ukoliko je privreda u ravnoteži. Ipak, isticao je da je kratkoročni uticaj inflacije moguć, ali kako novčana iluzija nije trajna, inflacija ne može dugoročno pozitivno da utiče na privrednu aktivnost.[11]

1.1.3. „Ja sam otkrio Filipsovu krivu“ – *Irving Fisher*

U dvadesetom vijeku se po prvi put piše i priča o odnosu između inflacije i nezaposlenosti na osnovu empirijskih studija. Nedostatak statističkih podataka i empirijskih studija je i razlog zašto se često u literaturi ne spominju rani začeci ideje o Filipsovoj krivoj, jer nisu postojali konkretni dokazi.

Na isti način kao što su *Hume* i *Thornton* pomogli u teorijskom formulisanju modela, tako je i *Irving Fisher (1867 – 1947)* doprinio u dokazivanju postojanja modela na osnovu realnih podataka o promjenama cijena i nezaposlenosti. U svom radu „*Statistička veza između nezaposlenosti i promjene cijena”*[12] iz 1926. godine, zapazio je visoku korelisanost između promjene cijena i nezaposlenosti, a opisao je i metode kojima je postigao ovaj rezultat. Kako je *Fisher* naglasio, podaci koje je koristio odnose se samo na stanje u Americi, pa bi bila potrebna dalja istraživanja prije zaključka da li bi ova međuzavisnost mogla da se potvrdi i u drugim državama van Amerike. Istraživao je vezu između nezaposlenosti (U) i promjene cijena sa kašnjenjem ($(dP/dt)_L$), gdje indeks L označava linearno raspoređeno kašnjenje[13] varijable promjena cijena. Koristeći mjesečne podatke za period od 1915. do 1925. godine, dobija da je koeficijent korelacije između ove dvije varijable čak 90%. Na ***Grafiku 1***. prikazana je slična jaka povezanost između zaposlenosti i kašnjenja u promjeni cijena. Ovakav odnos posmatranih varijabli mu je ukazao da postoji snažna korelacija između istih.

[11] Humphrey, Thomas M. “Two Views of Monetary Policy: The Attwood-Mill Debate Revisited.” Economic Review, Federal Reserve Bank of Richmond 63 (September/October 1977), pp. 14-22.

[12] *Jacob Mincer*, profesor sa Univerziteta Kolumbija, sasvim slučajno je otkrio ovaj *Fisher*-ov rad, dok su u isto vrijeme potpuno nezavisno od njegovog otkrića, rad pronašli i *A. Donner* i *J. F . McCallum* i citirali ga u svom radu *“The Philips Curve: An Historical Note”*, Economica, 1972, pp. 322-23.

[13] Sam *Fisher* je izumitelj koncepta distribucije kašnjenja.

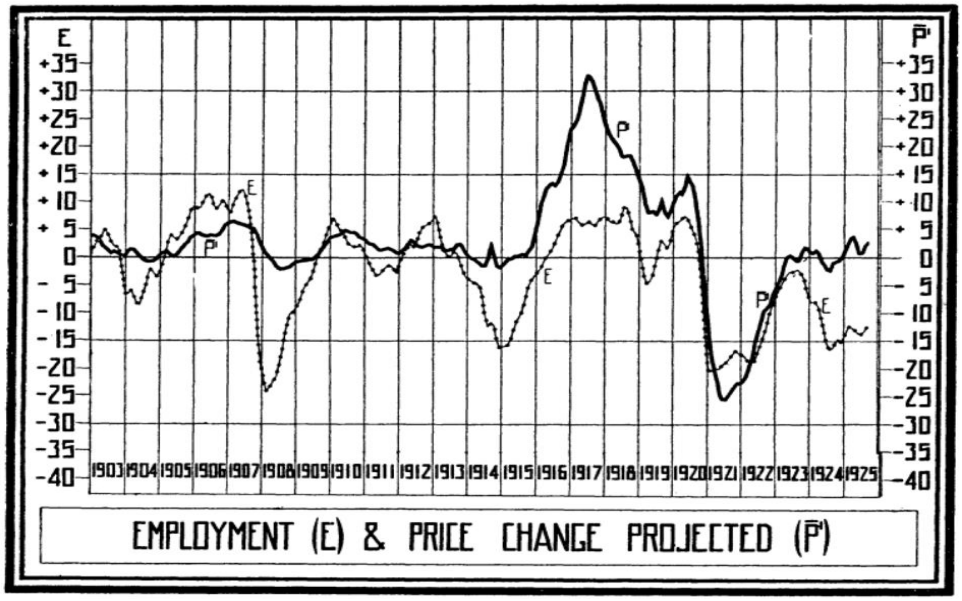

***Grafik 1**: Odnos između nezaposlenosti i promjene cijena*

Izvor: Fisher, Irving. "A Statistical Relation between Unemployment and Price Changes." International Labour Review 13 (June 1926): 785-92. Reprinted as "I Discovered the Phillips Curve." Journal of Political Economy 81 (March/April 1973): p. 502.

Fisher je zaključio da ova relacija nije samo kauzalna, već i empirijska, a da za njeno pojavljivanje postoje dobri teorijski razlozi. Njegova teorija, od cijena do nezaposlenosti, zasniva se na fiksnim ugovorima, sporim prilagođavanjima i drugim inhibišućim faktorima koji preveniraju troškove da se prilagode istom brzinom kao cijene, kada se cijene mijenjaju. Zbog zaostajanja troškova za cijenama, promjene na kraju utiču na profit i samim tim na nivo realne aktivnosti i zaposlenosti. Preko ove veze, uzročnost, kako je isticao, ide od inflacije do nezaposlenosti, što je potvrđeno njegovim empirijskim nalazom.[14]

Iako je *Fisher* bio prvi koji je na osnovu empirijskih dokaza potvrdio kauzalnost između inflacije i nezaposlenosti, on nije formirao formalnu ekonometrijsku jednačinu. Nakon njega su, *Jan Tinbergen*, *Klein* i *Goldberger*, a posebno *A. J. Brown* i *Paul Sultan*, dali svoj doprinos da ovaj teorijski koncept, još prije *Philips*-a, bude predstavljen i ekonometrijskom jednačinom. *Paul Sultan* je predstavio svoju krivu godinu dana prije *Philips*-a (1957) u knjizi *Labour Economics* i tu je istakao sljedeće: *„Na vertikalnoj osi je predstavljena godišnja promjena u nivou cijena (u procentima), dok je na horizontalnoj osi procenat nezaposlene radne snage. Linija koja povezuje nezaposlenost i inflaciju je striktno hipotetička. U ovom hipotetičkom slučaju, pretpostavlja se da kada je nezaposlenost manja od 2% od ukupne radne snage, suočavamo se s opasnošću od inflacije. A kada je nezaposlenost veća od 6%, suočavamo se sa problemom ozbiljne deflacije."*[15]

[14] Fisher, Irving. "A Statistical Relation between Unemployment and Price Changes." International Labour Review 13 (June 1926): 785-92. Reprinted as "I Discovered the Phillips Curve." Journal of Political Economy 81 (March/April 1973): pp. 496-502.

[15] Sultan, Paul (1957), *Labor Economics*, New York: Henry Holt and Company, p. 555.

Međutim, kako nijedan *Philips*-ov prethodnik nije uspio da primijeti i iscrta uočljivu opadajuću krivu između inflacije i nezaposlenosti na način na koji je to uradio on, model je istrajao u tome da, uprkos vremenu i razvoju krive kroz više sukcesivnih verzija, zadrži naziv Filipsova kriva. Nakon perioda standardne Filipsove krive, zbog burnih ekonomskih promjena, model dobija mnogo više na značaju i u teorijskom i u empirijskom smislu, a posebno mjesto je zauzeo u kreiranju ekonomske politike. Iz tog razloga, ovdje su izdvojene četiri faze kroz koje je model prošao:[16]

1. odnos rast nadnica – rast nezaposlenosti (*A. W. Philips*);
2. odnos inflacija – nezaposlenost (*P. Samuelson, R. Solow, R. Lipsey*);
3. adaptivna očekivanja (*M. Friedman*),
4. racionalna očekivanja (*T. Sargent, R. Lukas*).

Prve dvije faze će biti pojašnjene u okviru ***Poglavlja 1.2. - Standardna Filipsova kriva,*** dok će u ***Poglavljima 1.3. i 1.4. (Filipsova kriva sa adaptivnim i racionalnim očekivanjima)*** biti objašnjene treća i četvrta faza u razvoju Filipsove krive.

1.2. Standardna Filipsova kriva[17]

A. W. Philips, novozelandski ekonomista, je 1958. godine dao do tada najbolju formulaciju modela Filipsove krive. On je u svojoj studiji, na primjeru Engleske, doveo u odnos stopu nezaposlenosti i stopu promjene plata. Došao je do otkrića da je u periodu od 1861. do 1957. godine postojao inverzni odnos između stope nezaposlenosti i stope promjene plata, odnosno stopa nezaposlenosti je bila manja u godinama kada dolazi do relativno većeg povećanja nadnica, dok je rasla kada se nadnice relativno malo povećaju. Bez obzira na to što je ovo zapravo bio njegov najuticajniji rad, on ga je opisivao kao rad koji je „završio za jednu nedelju", „posao na brzinu", „veoma krut pokušaj".[18]

Međutim, vrlo brzo nakon *Philips*-ovog istraživanja veliki broj ekonomista je počeo da sprovodi isto istraživanje i u drugim zemljama. *Solow* i *Samuelson* su modifikovali Filipsovu krivu tako što su varijablu stopa promjene plata zamijenili stopom inflacije. U ovom obliku Filipsovu krivu su počeli masovno da koriste kreatori makroekonomske politike, u želji da što preciznije definišu uslove koji bi vodili ka visokoj stopi zaposlenosti i relativno stabilnim cijenama.[19]

---

[16] Jakšić, M. (2005). *Osnovi makroekonomije*. Centar za izdavačku delatnost Ekonomskog fakulteta., str. 247.
[17] U literaturi se za standardnu Filipsovu krivu koriste i sljedeći sinonimi: originalna, izvorna, tradicionalna, zvanična Filipsova kriva.
[18] Schwarzer, J. A. (2012). AW Phillips and his curve: Stabilisation policies, inflation expectations and the 'menu of choice'. The European Journal of the History of Economic Thought, 19(6), 976-1003.
[19] Sekulović, M., Kitanović, D., & Cvetanović, S. (1997). Makroekonomija. Zavod za udžbenike i nastavna sredstva, str. 336.

Na ***Slici 1***. je prikazana opadajuća kriva koja predstavlja inverzan odnos između stope promjene nadnica i stope nezaposlenosti, a u ekonomskoj teoriji se zove originalna ili kratkoročna Filipsova kriva. Na apscisi je prikazana stopa nezaposlenosti, dok je na ordinati predstavljena stopa inflacije (stopa promjene nadnica). Opadajuća kriva pokazuje da kada je nezaposlenost na niskom nivou onda je stopa inflacije visoka, i obrnuto. Ovako definisana kratkoročna Filipsova kriva je tokom šezdesetih godina služila za kreiranje makroekonomske politike u Sjedinjenim Američkim Državama.

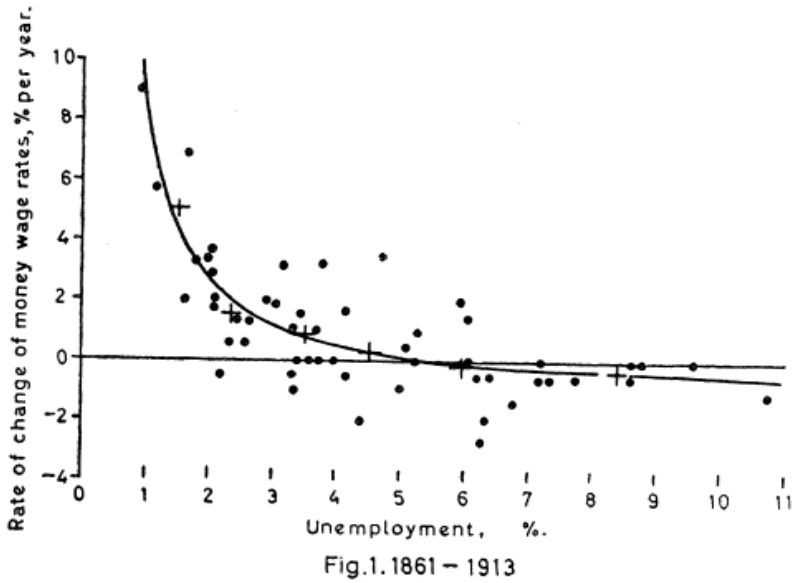

Slika 1*: Tradicionalna Filipsova kriva*

Izvor: Phillips, A. W. (1958). The relation between unemployment and the rate of change of money wage rates in the United Kingdom, 1861-1957. Economica, 25(100), p. 285.

Standardna Filipsova kriva je negativnog nagiba, pa kretanje duž krive i ka gore pokazuje da je za jednako smanjenje stope nezaposlenosti porast inflacije sve veći, da bi poslije određenog nivoa dodatno smanjivanje stope nezaposlenosti vodilo vrlo visokim stopama inflacije, a posljedično i ugrožavanju privredne stabilnosti. Cilj kreatora makroekonomske politike jeste niska stopa nezaposlenosti i niska inflacija, međutim, podaci i na osnovu njih izvedena Filipsova kriva ukazuju da je takva kombinacija izbora teško ostvariva.[20]

Iako sam *Philips*, u tom periodu, nije razmatrao upotrebu modela u kreiranju ekonomske politike, *Solow* i *Samuelson* su interpretirali Filipsovu krivu kao „meni" mogućih političkih izbora stope inflacije i stope nezaposlenosti između kojih su vlasti mogle da izaberu najpovoljniju kombinaciju, a zatim, koristeći instrumente politike, to i postignu. Ovakvo tumačenje je doprinijelo popularnosti

[20] Benić, Đ. (2014). Povijest razvoja teorije o odnosu između inflacije i nezaposlenosti. *Ekonomska misao i praksa*, (2), str. 413.

Filipsove krive među kenzijanskim političkim savjetnicima, pa su počeli da je koriste kao analitički instrument ekonomske politike.[21] Kenzijanci su Filipsovu krivu, zajedno uz IS-LM model, upotrebljavali da objasne šta se u ekonomiji dešava na kratak rok. Oni smatraju da se sistem, po pravilu, nalazi u stanju neravnoteže, pa ekonomska politika treba permanentno i u kratkom roku da djeluje u pravcu korigovanja performansi ekonomije. Neophodno je voditi kratkoročnu monetarnu i fiskalnu politiku „finog usklađivanja" realnih procesa, u cilju podsticanja realnog rasta uz izvjesnu pažnju da ne dođe do previsokog rasta inflacije. Takođe, zastupali su intervencionističku ekonomsku politiku, koja će otkloniti slabosti tržišta i sistem dovesti u stanje približno pune zaposlenosti, odnosno kreatori ekonomske politike treba da vode diskrecionu politiku.[22]

Za kenzijansku teoriju Filipsova kriva je osnov za državnu intervenciju. Smatrali su da je nevoljna nezaposlenost najveći ekonomski problem i da ekonomska politika (posebno fiskalna) mora biti aktivna u smanjenju nezaposlenosti, na uštrb veće inflacije, koja je po njima bila drugorazredni ekonomski problem. Ovakva kenzijanska ekonomska politika ukazuje na to da bi bilo politički isplativo da se kreira ekspanzivna politika i poveća zaposlenost, ali kada je potrebno da se sprovedu restriktivne mjere u cilju suzbijanja inflacije mora se platiti cijena veće nezaposlenosti, a ta cijena se plaća na izborima.

Ovakvo rano izlaganje i tumačenje *Philips*-ovog rada, od strane kenzijanaca, je jedan od glavnih razloga što je model dobio ime upravo po *Philips*-u. Osim toga, on je prvi imao upečatljiv nalaz o očiglednoj skoro stogodišnjoj empirijskoj stabilnosti krive, na koju se ranije nije sumnjalo.

1.3. Filipsova kriva sa adaptivnim očekivanjima

Definisanje očekivanja u makroekonomiji ima jako važnu ulogu u razumijevanju kratkoročnog odnosa između stope inflacije i stope nezaposlenosti. Očekivanja se mogu formirati na različite načine, ali ovdje će biti izdvojene dvije vrste očekivanja, koja su po mišljenju istaknutih ekonomista značajno uticala na odnos stope inflacije i stope nezaposlenosti, a to su: adaptivna i racionalna očekivanja.

Adaptivna su ona očekivanja koja se zasnivaju na informacijama iz prošlosti. U svakodnevnom životu, npr. ukoliko pekare u zemlji proizvode hljeb odličnog ukusa, već pet godina, očekuje se da će pekare zadržati kvalitet proizvoda i u budućnosti. Ukoliko kvalitet opadne, potrošači se vremenom prilagode na takvo stanje, jer je hljeb neophodan a boljeg nema. Isto tako i u ekonomiji, ukoliko Evropska centralna banka (ECB) npr. održava stopu inflacije ispod 2% poslednjih najmanje pet godina, onda će stanovništvo očekivati cjenovnu stabilnost i u narednom periodu.

[21] Samuelson, P. A., & Solow, R. M. (1960). Analytical aspects of anti-inflation policy. *The American Economic Review*, *50*(2), pp. 177-194.
[22] Dimitrijević, B., Fabris, N., Vladušić, L., Radović, M., & Jandrić, M. (2016). *Ekonomska politika–regionalni aspekti. Economic policy–regional aspects]*. Belgrade: Faculty of Economics, str. 62-64.

Međutim, ukoliko ECB poveća stopu inflacije dvostruko, javnost će biti iznenađena. Takva neočekivana inflacija dovodi do kratkoročnog *tradeoff*-a između stope inflacije i stope nezaposlenosti. Ukoliko tokom vremena inflacija ostane na "novom", povećanom nivou stanovništvo će prilagoditi očekivanja trenutnoj stopi inflacije, pa se privreda vraća na prirodnu stopu nezaposlenosti duž kratkoročne Filipsove krive. Nedostatak adaptivnih očekivanja je što se baziraju na informacijama iz prošlosti, zanemarujući bitne informacije iz tekućeg perioda.

S obzirom na to da Filipsova kriva predstavlja *tradeoff* između inflacije i nezaposlenosti, kreatori ekonomske politike su pokušavali da "kupe" što viši nivo zaposlenosti, a da pritom ne izazovu istovremeni porast inflacije. Ta politika može dati dobre rezultate ali samo pod uslovom da pojedini institucionalizovani sektori makroekonomije imaju pogrešna očekivanja. Na primjer, ukoliko se nominalne najamnine povećaju, ponuda rada će biti veća i u toj situaciji rast inflacije, i rast najamnina, koji je sa njom povezan, mogu smanjiti nezaposlenost.[23] Međutim, tokom dužeg vremenskog perioda stanovništvo počinje da primjećuje da ne raste samo cijena rada već i sve ostale cijene u ekonomiji, odnosno rast nominalnih ne znači i rast realnih najamnina. Plata zaposlenih jeste porasla, ali sa njom su porasle i cijene svih usluga i dobara, pa samim tim ni kupovna moć stanovništva nije veća, iako to kratkoročno drugačije izgleda.

Pošto stanovništvo vremenom postaje svjesno da nominalni rast najamnina zapravo nije realan, ponuda rada se ne povećava. Poslodavci smanjuju tražnju za radom, jer zaposleni zahtijevaju povećanje realnih zarada, što vodi smanjenju profita. Zaključak je da je Filipsova kriva fenomen koji ne važi dugoročno, što su monetaristi dokazali konceptom prirodne stope nezaposlenosti.

Monetaristi su smatrali da kada je inflacija očekivana, nezaposlenost će biti jednaka prirodnoj stopi nezaposlenosti, bez obzira na to kolika je očekivana inflacija. Kada je stvarna inflacija viša od očekivane, nezaposlenost je ispod nivoa prirodne stope nezaposlenosti. U slučaju da je stvarna inflacija niža od očekivane, nezaposlenost će biti veća od prirodne stope nezaposlenosti. Suština je da je prirodna stopa nezaposlenosti nezavisna varijabla kada je očekivana inflacija jednaka stvarnoj, dok se stopa nezaposlenosti ne podudara sa prirodnom stopom nezaposlenosti samo kada stanovništvo ne formira očekivanja povodom inflacije.

[23] Sekulović, M., Kitanović, D., & Cvetanović, S. (1997). *Makroekonomija*. Zavod za udžbenike i nastavna sredstva., str. 339.

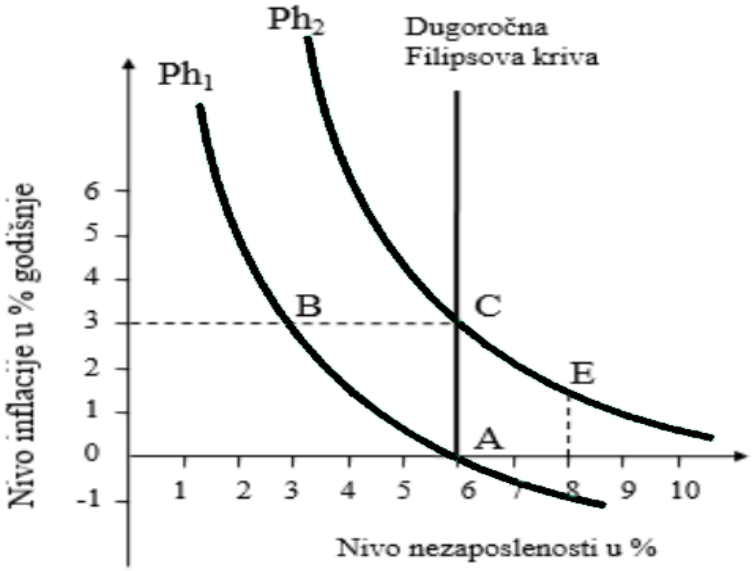

***Slika 2**: Dugoročna Filipsova kriva*
***Izvor:** Sekulović, M., Kitanović, D., & Cvetanović, S. (1997). Makroekonomija. Zavod za udžbenike i nastavna sredstva, str. 343.*

Na ***Slici 2.*** dugoročna Filipsova kriva se poklapa sa prirodnom stopom nezaposlenosti, koja je predstavljena pravom vertikalnom linijom. Nastala je spajanjem tačaka presjeka mnogobrojnih kratkoročnih Filipsovih krivih i prirodne stope nezaposlenosti. U tački A dolazi do presjeka kratkoročne Filipsove krive (Ph1) i nivoa nezaposlenosti od 6%, tu je stvarna inflacija jednaka očekivanoj. Ukoliko se nivo inflacije neočekivano poveća na 3% privreda se kreće duž kratkoročne Filipsove krive Ph1, u tačku B, gdje je nivo nezaposlenosti 3%, umjesto prirodne stope od 6%. Ako se čitav ovaj proces posmatra kroz model agregatna ponuda – agregatna tražnja (AS – AD model) može se vidjeti da dolazi do kretanja duž kratkoročne krive agregatne ponude udesno i naviše poslije pomjeranja krive agregatne tražnje. Ovo pomjeranje vodi ka povećanju realnog nacionalnog dohotka, rastu inflacije i padu nezaposlenosti. Ukoliko stopa inflacije ne pređe 3%, stanovništvo će se adaptirati i to će postati očekivani nivo inflacije. U tom trenutku dolazi do podudaranja krive agregatne tražnje i krive kratkoročne ponude, dok se realni nacionalni proizvod i nezaposlenost vraćaju na prirodan nivo. Takođe, kriva agregatne tražnje i kratkoročna kriva agregatne ponude pomjeraju se naviše, duž dugoročne krive agregatne ponude sa nepromijenjenim nivoom inflacije od 3%. Na ***Slici 2.*** to je prikazano translacijom kratkoročne Filipsove krive (Ph1) udesno u položaj Ph2. Rezultat je pomjeranje privrede u tačku C. Zaključak je da se sve kratkoročne Filipsove krive, u zavisnosti od povećanja očekivane inflacije, pomjeraju naviše duž dugoročne Filipsove krive, koja se nalazi na prirodnoj stopi nezaposlenosti. Suština je da dugoročna Filipsova kriva, prikazana vertikalnom linijom, pokazuje da je na dugi rok stopa nezaposlenosti nezavisna od stope inflacije. Dakle, dugoročno gledano, povećana inflacije neće smanjiti nezaposlenost.[24]

[24] M.Sekulović, D. Kitanović, op. cit., str. 342-344.

1.4. Filipsova kriva sa racionalnim očekivanjima

Nedostatak adaptivnih očekivanja je to što ne uključuju mogućnost da ljudi uče na greškama iz prošlosti. Na osnovu kritike adaptivnih očekivanja, *Robert Emreson Lucas*[25], u model Filipsove krive uvodi pretpostavku racionalnih očekivanja. Racionalna očekivanja se zasnivaju na razmatranju i povezivanju informacija iz prošlog, tekućeg, ali i budućeg vremenskog perioda, što je mnogo širi koncept u odnosu na adaptivna očekivanja.

Lucas je smatrao da nova klasična Filipsova kriva, baš kao i *Friedman*-ova, pokazuje *tradeoff* između inflacije i nezaposlenosti, međutim razlika postoji u tome što je mnogo teže iznenaditi ekonomske subjekte ako svoja očekivanja formiraju racionalno. Dok u monetarističkom okviru, sa adaptivnim očekivanjima, čak i politike zasnovane na pravilima mogu generisati neočekivanu inflaciju, to nije moguće u novoj klasičnoj školi. Brzina prilagođavanja očekivanja je takođe mnogo veća nakon greške u prognozi.

Lucas zahtijeva kreiranje politike u skladu sa pravilima, kako akteri ne bi bili iznenađeni. U potpunosti odbacuje primjenu diskrecionih prava od strane kreatora ekonomske politike, jer je diskreciona politika ad hoc politika, sklona zloupotrebama, posebno u periodu izbornih ciklusa kada vlast vodi ekspanzivnu politiku. Takva politika je nekredibilna i nekompetentna. Teoretičari racionalnih očekivanja čak zahtijevaju da se formulišu ustavna pravila u kreiranju politika kako ne bi bilo prevara od strane monetarnih vlasti. Ukoliko postoji povjerenje u institucije, npr. u Centralnu banku, a ona umjesto najavljene niske ponude novca krene u ekspanzivnu politiku, stvarna inflacija postaje veća od očekivane inflacije. Dakle, dolazi do neanticipiranih promjena. Prihodi preduzeća rastu brže od troškova (tj. troškova zarada, jer zarade rastu po očekivanoj stopi inflacije koja je ugrađena u kolektivne ugovore). U tom periodu poslodavcima se isplati da angažuju nove radnike. Međutim, ovo može trajati samo kratko jer radnici traže usklađivanje zarada sa stvarnom inflacijom, pa dolazi do vraćanja na dugoročnu krivu.[26]

Ideja o jakoj državi i ograničenom djelovanju vlade u ekonomskoj sferi su komplementarne. Ograničeno djelovanje treba da bude podržano državnim institucijama koje će biti dovoljno sposobne da obezbijede slobodno djelovanje tržišta, obezbjeđujući na taj način sigurnost, konkurenciju, vladavinu zakona, kao i makroekonomsku stabilnost, oličenu u cjenovnoj stabilnosti.[27]

---

[25] *Robert Emerson Lucas* je američki ekonomista i dobitnik Nobelove nagrade (1995. godine) za razvoj i primjenu teorije racionalnih očekivanja. Diplomirao je istoriju 1959. godine, a doktorirao ekonomiju 1964. godine na Univerzitetu Čikago.

[26] Motyovszki, G. E. R. G. Ő. (2013). *The evolution of the Phillips curve concepts and their implications for economic policy. History of Economic Thought*, Term Paper, Central European University., p. 7.

[27] Jakšić, M., & Praščević, A. (2010). *Politička makroekonomija*. Beograd: Ekonomski fakultet Univerziteta u Beogradu., str. 158.

1.5. Otvorena pitanja u vezi sa Filipsovom krivom

Koliko je Filipsova kriva, pri samom otkriću, zaintrigirala ekonomiste širom svijeta, toliko se brzo počelo sumnjati u valjanosti njene teorijske postavke u praksi. Prvi ekonomisti koji su počeli da preispituju utemeljenost Filipsove krive bili su nobelovci *Milton Friedman* i *Edmund Phelps*. Oni su se pitali kako može da postoji dugoročna veza između stope rasta neke nominalne varijable (kao što su nominalne zarade i cijene) i promjene realnih varijabli kao što su zaposlenost, nezaposlenost i proizvodnja? Ako bi se radnici i firme vodili jedino rastom sopstvenih cijena ili zarada, a da se pritom ne interesuju da li ostale cijene u zemlji rastu, oni bi podlegli tzv. iluziji novca i samo u tom slučaju bi dohodak porastao.[28]

Ono u šta su *Friedman* i *Phelps* sumnjali počelo je krajem 1970-ih i početkom 1980-ih da bude opravdano. U tom periodu dolazi do istovremenog porasta i stope inflacije i stope nezaposlenosti, odnosno stagflacije. Dolazi do nestanka Filipsove krive što je imalo veliki uticaj na kreiranje ekonomske politike, koja se od tog trenutka počela zasnivati na principu monetarne neutralnosti. Pred makroekonomistima je stajao izazov kako da objasne povremeno nestajanje inverznog odnosa između inflacije i nezaposlenosti, koji je do tog trenutka bio osnova za vođenje makroekonomske politike širom svijeta. Nagli istovremeni porast inflacije i nezaposlenosti se direktno vezuje za dva naftna šoka, kada su se cijene nafte značajno povećale (detaljnije u ***Poglavlju 1.5.1.***). Bitno je naglasiti da bez obzira na početak negiranja Filipsove krive, ona je ponovo registrovana i to u periodima između naftnih šokova kao i poslije drugog naftnog šoka i to svaki put iznad i udesno u odnosu na predhodnu.[29]

Gregory Mankiw je u svom radu *„The inexorable and mysterious tradeoff between inflation and unemployment" (2000.)* rekao sljedeće: „Postoje i loše i dobre vijesti kada je u pitanju odnos inflacije i nezaposlenosti. Dobra vijest je što *tradeoff* inflacija - nezaposlenost ima sigurno mjesto u ekonomiji (u drugom izdanju mog udžbenika i dalje je jedan od deset osnovnih principa ekonomije). Skoro svi ekonomisti su danas saglasni, da monetarna politika utiče na nezaposlenost, barem privremeno, a nivo inflacije determiniše barem u dugom roku. To je sve u šta treba da vjerujemo da bismo prihvatili inverzan odnos inflacije i nezaposlenosti kao jedno od osnovnih načela ekonomije. Takođe, teorija koja stoji iza Filipsove krive je razumljiva. Loša vijest je što dinamička povezanost inflacije i nezaposlenosti i dalje ostaje misterija. Takozvana „nova Kenzijanska Filipsova kriva" je privlačna sa teorijskog stanovišta, ali je i momentalni neuspjeh. Nije u skladu sa standardnim stilizovanim činjenicama o dinamičkim efektima monetarne politike prema kojima monetarni šokovi kasne i postepenog su uticaja na inflaciju. Ove činjenice možemo objasniti tradicionalnim gledanjem unazad modelima dinamike inflacije-nezaposlenosti, ali ovim modelima nedostaje bilo kakvo utemeljenje u mikroekonomskoj teoriji prilagođavanja cijena. Možda su ove loše vijesti zapravo dobre vijesti za nauku. Oblasti istraživanja privlače

[28] Burda, M., & Viploš, Č. (2012). *Makroekonomija*: evropski udžbenik, prevod 5. izd. Ekonomski fakultet, Centar za izdavačku delatnost, Beograd, str. 293.
[29] M. Burda, Č. Viploš, op. cit., str. 293-294.

interesovanje kada postoje izvanredne naučne zagonetke koje treba riješiti. Nije vjerovatno da će ekonomska profesija ikada odbaciti kompromis između inflacije i nezaposlenosti u kratkom roku, tako da je bolje da nastavi sa zadatkom koji ima za cilj da ih objasni."[30]

Upravo ove činjenice održavaju Filipsovu krivu interesantnom ekonomistima širom svijeta, u želji da uz pomoć ovog jednostavnog a važnog modela pokušaju da kreiraju ekonomsku politiku, dok bi istovremeno omogućili predviđanje dva bitna makroekonomska indikatora kao što su stopa inflacije i stopa nezaposlenosti.

1.5.1. Istovremeni porast inflacije i nezaposlenosti – stagflacija

Iskustvo je pokazalo da Filipsova kriva ima analitičku vrijednost samo kratkoročno, dok dugoročno iako je nivo nezaposlenosti visok, inflacija može da poraste, odnosno može doći do stagflacije (istovremenog porasta nezaposlenosti i inflacije). Najčešći primer stagflacije je naftna kriza iz 1970-ih. U oktobru 1973. godine, Organizacija zemalja izvoznica nafte (OPEK) proglasila je embargo na isporuku nafte Sjedinjenim Državama i evropskim saveznicima Izraela kao odgovor na zapadnu podršku Izraelu tokom *Yom Kippur* rata.

Embargo na naftu je odmah doveo do povećanja cijena nafte za preko 300%, što je izazvalo ogromne probleme u SAD-u, gdje su cijene nafte ostale na visokom nivou, čak i nakon što je embargo okončan u martu 1974. godine. To se poklopilo sa preseljenjem proizvodnih pogona van SAD-a, kako bi se uštedjeli troškovi rada i rastući troškovi rata u Vijetnamu i dovelo do produženog perioda stagflacije, gdje su visoke cijene nafte izazvale brzi rast inflacije, povećanje nezaposlenosti i stagnaciju privrede. Na ***Slici 3.*** predstavljena je veza između inflacije i nezaposlenosti u SAD-u, u periodu od 1961. do 1995. godine, i može se jasno vidjeti da se ne prepoznaje putanja opadajuće Filipsove krive, već da su kretanja ovih makroekonomskih indikatora nepredvidljiva, što je bila posljedica većeg broja eksternih šokova u tom periodu.

[30] Mankiw, N. G. (2001). *The inexorable and mysterious tradeoff between inflation and unemployment*. The Economic Journal, 111(471), pp. 45-61.

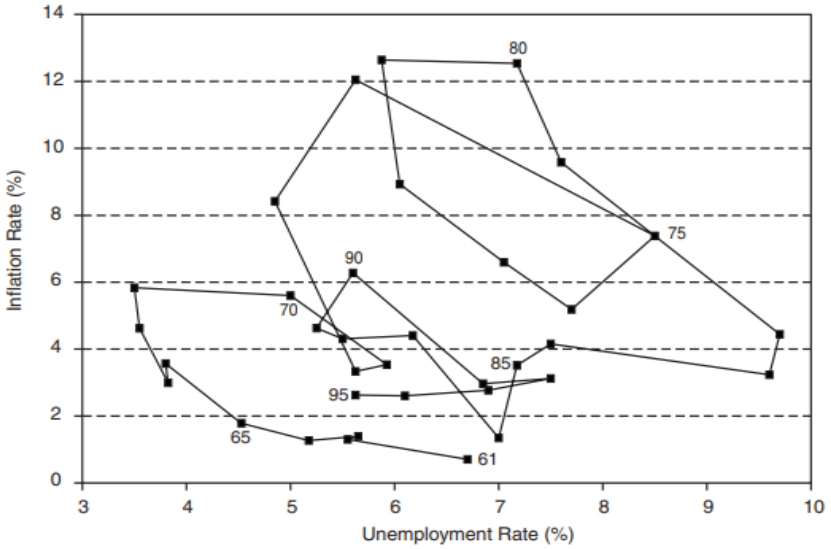

***Slika 3**: Veza između inflacije i nezaposlenosti u Sjedinjenim Američkim Državama, 1961-1995*
***Izvor:** Bureau of Labor Statistics/Haver Analytics*

Preokret američke ekonomije od proizvodnje ka poslovima u uslugama, sa manje dobrom nadoknadom, doveo je do prestanka rasta realnih plata, gubitka povjerenja potrošača i smanjenja potrošnje, što je dodatno pogoršalo krizu.

Predsjednik *Richard Nixon* pokušao je da ublaži stagflaciju iz 1970-ih tako što je devalvirao dolar i proglasio zamrzavanje cijena i plata. Međutim, ta strategija nije funkcionisala i *Jeremy Siegel*, istaknuti ekonomista, smatra je jednom od velikih promašaja američke makroekonomske politike. Mnogi ekonomisti sada vjeruju da je rast novčane mase od strane Federalnih rezervi bio glavni faktor u stagflacionoj krizi 1970-ih. Promjena u kreiranju ekonomske politike kako bi se ona fokusirala na nisku nezaposlenost i stabilnost cijena bila je neophodna da bi se zaustavila stagflacija.

1.5.2. Okunov zakon – empirijska veza između zaposlenosti i bruto društvenog proizvoda

Filipsova kriva, koja prikazuje inverzni odnos između stope inflacije i stope nezaposlenosti, je neodvojiva od Okunovog zakona, koji govori o zavisnosti nezaposlenosti i privrednog rasta, a čiji je autor *Arthur Okun*.

Okunov zakon glasi: „Ukoliko je nezaposlenost za 1% iznad prirodne stope nezaposlenosi gep društvenog bruto proizvoda (manjak društvenog proizvoda u odnosu na društveni proizvod na

nivou pune zaposlenosti) iznosi 2,5%.“[31] Okunova kriva predstavlja odstupanje stvarnog u odnosu na potencijalni društveni proizvod usljed nezaposlenosti.[32]

Kada je agregatna tražnja za radom manja, na makronivou dolazi do veće stope nezaposlenosti, dok će veća tražnja za radnom snagom imati suprotan efekat. Veća agregatna tražnja za radom će dovesti do većeg nivoa bruto društvenog proizvoda, i obrnuto, što bi značilo da visoke stope nezaposlenosti vode padu društvenog proizvoda. Okunova kriva potvrđuje inverznu korelaciju između nezaposlenosti i stope privrednog rasta. Ukoliko u makroekonomiji dođe do smanjenja nezaposlenosti doći će do smanjenja gubitka potencijalnog bruto društvenog proizvoda, a u slučaju rasta nezaposlenosti dolazi do povećanja jaza koji dijeli potencijalni od realnog bruto društvenog proizvoda.[33]

[31] McConnell, C. R., Brue, S. L., & Flynn, S. M. (2009). *Economics: Principles, problems, and policies*. Boston McGraw-Hill/Irwin.
[32] Jakšić, M. (2005). *Osnovi makroekonomije*. Centar za izdavačku delatnost Ekonomskog fakulteta, str. 250.
[33] Sekulović, M., Kitanović, D., & Cvetanović, S. (1997). *Makroekonomija*. Zavod za udžbenike i nastavna sredstva., str. 328.

2. OSNOVNI PRINCIPI EKONOMETRIJSKOG MODELIRANJA

Teorija je *condicio sine qua non.*

Ekonometrija predstavlja „nauku koja primjenjuje metode matematičke statistike na ekonomske podatke u cilju analize valjanosti postavki ekonomske teorije“.[34] I kako kaže *Kennedy*: „*Njen osnovni zadatak je oživljavanje teorijskih struktura*“. Ekonometrija je multidisciplinarna oblast koja obuhvata metode i rezultate istraživanja ekonomije i statistike. Ekonometrijska istraživanja imaju za predmet analiziranje teorijski poznatih ekonomskih pojava, primjenom matematičkih i statističkih metoda, sa ciljem dodjeljivanja empirijske dimenzije ekonomskoj teoriji.

Uslovi koje je neophodno da jedna ekonomska pojava ispuni da bi mogla biti predmet ekonometrijskih istraživanja su: *nepromjenljivost ili relativna stabilnost* ekonomske pojave u vremenu. U društvenim naukama ispitivane pojave i fenomeni su dinamičkog karaktera, iz tog razloga se naglašava pojam relativne stabilnosti. Na primjer, kada se u ekonomiji ispituje stopa inflacije ne može se očekivati da će ona dugoročno, prateći je na mjesečnom nivou, imati istu vrijednost za svaki mjesec. Razlozi za to mogu biti mnogobrojni: kupovna moć stanovništva, (ne)posjedovanje sopstvene valute, ekonomska politika koja se vodi u zemlji (ekspanzivna ili restriktivna), zaduženost zemlje u inostranstvu, ratno stanje i slično; *odabir faktora* koji presudno utiču na analiziranu pojavu i njihovo odvajanje od faktora koji nijesu značajni za analizu i čiji je uticaj slučajan; *mogućnost kvantifikovanja pojava* koje se analiziraju; *postojanje kvalitetne baze statističkih podataka* koja se upotrebljava prilikom istraživanja.

Tri osnovna cilja ekonometrije su:[35]

1. *Testiranje ekonomske teorije* (ispitivanje realnosti da bi se bolje upoznale i razumijele ekonomske pojave i aktivnosti);
2. *Pomoć u donošenju odluka* i to bilo na mikroekonomskom nivou, bilo u ekonomskoj politici, jer su optimalne ekonomske odluke uslovljene vrijednostima dobijenih numeričkih ocjena parametara ekonomskih relacija.
3. *Predviđanje*, tj. korišćenje numeričkih ocjena ekonometrijskog modela da bi se predvidjele buduće vrijednosti ekonomskih veličina.

Postizanje navedenih ekonomertijskih ciljeva se odvija kroz: specifikaciju adekvatnog ekonometrijskog modela, ocjenjivanje modela na osnovu realnih podataka, testiranje ocjena i testiranje moći predviđanja modela.

[34] A. S. Goldbergera, *Econometric Theory*, Wiley, New York, 1964.
[35] Jovičić, M., Dragutinović Mitrović R. (2011). *Ekonometrijski metodi i modeli*, Centar za izdavačku djelatnost Ekonomskog fakulteta u Beogradu, str. 5.

Ekonomska teorija predstavlja osnov ekonometrijskog istraživanja s obzirom na to da se uz pomoć nje formiraju ekonomske relacije i tvrdnje. Ekonomska statistika obezbjeđuje podatke kojima se model konfrontira, dok ekonometrijski metodi služe za ocjenjivanje modela. Na osnovu dobijenih rezultata testira se teorijska postavka, odnosno polazna hipoteza, koja se u zavisnosti od rezultata prihvata ili odbacuje. U slučaju odbacivanja teorije (hipoteze) moguće je revidiranje iste i njeno ponovno testiranje na novom skupu podataka. Dobijeni rezultati mogu se koristiti za testiranje teorije ali i za predviđanje i donošenje ekonomskih odluka. Upravo iz tog razloga, u narednom pasusu, naglašeno je o čemu je važno voditi računa prilikom formulisanja ekonometrijskog modela.

Kako ističu Dragutinović Mitrović i Jovičić bitno je da model karakteriše: [36]

- *relevantnost*, odnosno zasnovanost cilja;
- *teorijska uvjerljivost* – model treba da je usaglašen sa postulatima ekonomske teorije i da adekvatno predstavlja ekonomske fenomene;
- *sposobnost razjašnjavanja* – model treba uspješno da objasni opservacije iz stvarnosti, da bude konzistentan sa zapaženim ekonomskim ponašanjem;
- *tačnost ocjene parametara* – ocjene treba, na najbolji mogući način, da aproksimiraju stvarne parametre strukturnog modela i da posjeduju osobine nepristrasnosti i efikasnosti;
- *mogućnost predviđanja endogenih varijabli*;
- *jednostavnost* – model treba da predstavlja određenu ekonomsku vezu sa najvećom mogućom jednostavnošću, da bi se lako moglo razumjeti njegovo značenje, uz uslov da se druge željene osobine ne gube simplifikacijom modela.

Ekonometrijsko istraživanje postaje sve zastupljenije u naučno-istraživačkim radovima u ekonomiji pa je bitno naglasiti da se i pored rezultata u analizi i boljeg upoznavanja ekonomskih pojava i odnosa dolazi i do otkrivanja nekih novih metoda u okviru same ekonometrijske teorije. Te nove metode pokreću sve raznovrsnija i brojnija teorijska i empirijska istraživanja, tako da oblast ekonometrije obiluje značajnom literaturom koja bilježi porast iz dana u dan.

2.1. Osnovni koncepti analize vremenskih serija

Analiza vremenskih serija predstavlja jednu od statističkih disciplina koja možda i ponajviše dobija na značaju posljednjih decenija jer nije striktno vezana za ekonomiju, već je i u interakciji sa ostalim disciplinama. Vremenske serije se susrijeću u različitim oblastima ljudskog života, u demografiji, ekonomiji, medicini itd.

Postoji veliki broj definicija vremenskih serija, ovdje će biti izdvojena sljedeća: „Vremenska serija predstavlja skup kvantitativnih opservacija koje su poređane hronološki, pri čemu se vrijeme

[36] M. Jovičić, R. Dragutinović Mitrović, op. cit., str. 16.

posmatra diskretno, jer su tako bilježeni podaci. Formalni modeli vremenskih serija baziraju se na teoriji vjerovatnoće, koja polazi od stohastičkog procesa kao mehanizma generisanja podataka, pa se vremenska serija posmatra kao realizacija tog stohastičkog procesa".[37] Treba uzeti u obzir i to da se prilikom razmatranja ekonomskih vremenskih serija koriste diskretni podaci[38], u indeksu varijable se koristi oznaka za vrijeme *(t).* Budući da ekonomski subjekti ne reaguju istovremeno, jedan od osnovnih pojmova u analizi vremenskih serija je docnja ili kašnjenje (prva docnja y_{t-1}, druga docnja y_{t-2},... n-ta docnja y_{t-n}).

Suštinska razlika između klasične statističke analize i statističke analize vremenskih serija je u tome što su kod klasične statističke analize elementi slučajnog uzorka međusobno nezavisni. Kod analize vremenskih serija to nije slučaj, pa se pri analizi mora uzeti u obzir vremenski poredak opservacija. Ta međusobna zavisnost opservacija, kod analize vremenskih serija, se koristi u cilju formiranja modela vremenske serije. Zatim se, na osnovu numeričkih podataka slučajnih promjenljivih iz predhodnog perioda, prognoziraju buduća kretanja tih istih slučajnih promjenljivih.[39]

Osnovne komponente vremenskih serija, koje ujedno objašnjavaju i njihove glavne karakteristike, su[40]:

1. *Postojanje trenda*

Trend predstavlja dugoročnu razvojnu tendenciju neke pojave (***Slika 4. (b)***). Podaci najvećeg broja makroekonomskih vremenskih serija sistematski rastu ili opadaju tokom vremena, pri čemu ova tendencija rasta ili pada može biti ***stohastička ili deterministička***. Stohastički trend ukazuje da se u trenutku *t-1* ne može znati nivo promjenjive u trenutku *t*, dok se deterministički trend odnosi na funkciju oblika *a+bt*, koja određuje kretanje vremenske serije u svakom trenutku vremena. Da bi se analiziralo postojanje trenda prvo se provjerava da li trend uopšte postoji. Postojanje trenda uslovljava izbor funkcije trenda, koja će najviše odgovarati ispitivanoj seriji. Nakon toga se ocjenjuju parametri izabranog modela i na kraju se vrši prognoziranje ekstrapolacijom linije trenda u budućnosti.

2. *Postojanje sezonskih varijacija*

Sezonske varijacije (***Slika 4. (d)***) se javljaju redovno i periodično u rasponu kraćem od godinu dana. Imaju isti ili gotovo isti obrazac tokom perioda od 12 mjeseci i prisutne su u vremenskim serijama u kojima se podaci bilježe svakog sata, dnevno, nedeljno, kvartalno ili mjesečno. Npr.,

---

[37] Kirchgässner, G., & Wolters, J. (2007). *Introduction to modern time series analysis*. Springer Science & Business Media, p. 1.

[38] Ako su numeričke varijable diskretne (prekidne), one mogu imati samo određeni skup vrijednosti. Vrijednosti koje uzima diskretna slučajna promjenljiva su prebrojive i konačne.

[39] Kovačić, J.Z. (1995). *Analiza vremenskih serija*. Univerzitet u Beogradu, Ekonomski fakultet, str.2.

[40] Anderson, D. R., Sweeney, D. J., Williams, T. A., Camm, J. D., & Cochran, J. J. (2012). *Quantitative Methods for Business (Book Only)*. Cengage Learning, *pp. 191-197.*

kada je kišna sezona, prodaja kišobrana značajno raste, pa u tom vremenskom periodu serija bilježi nagli rast, dok tokom sunčanih dana dolazi do naglog pada iste vremenske serije.

3. *Postojanje cikličnih varijacija*

Ciklični obrazac (***Slika 4. (c)***) postoji ako grafikon vremenske serije pokazuje naizmjenični niz tačaka ispod i iznad linije trenda koji traje više od jedne godine. Ciklične varijacije mogu da budu regularne, ali nisu periodične. Mnogo ekonomskih vremenskih serija pokazuje ciklično ponašanje (npr., periodi umjerene inflacije praćeni periodima brze inflacije, mogu dovesti do vremenskih serija koje se smjenjuju ispod i iznad generalno rastuće linije trenda predstavljene npr. vremenskom serijom za troškove stanovanja).

4. *Neregularni uticaji*

Neregularni uticaji uzrokuju varijacije koje nijesu redovne i često su slučajne ili nepravilne. Kolebanja u kretanju vremenskih serija su nepredvidljiva i nekontolisana, pri čemu serija puno oscilira u određenom vremenskom periodu. Neregularni uticaji koji uzrokuju ovakve varijacije su: zemljotresi, ratovi, poplave i bilo koje druge katastrofe. Ovo svojstvo vremenskih serija se ispoljava i na finansijskim tržištima (cijene finansijskih instrumenata koje se brzo mijenjaju).

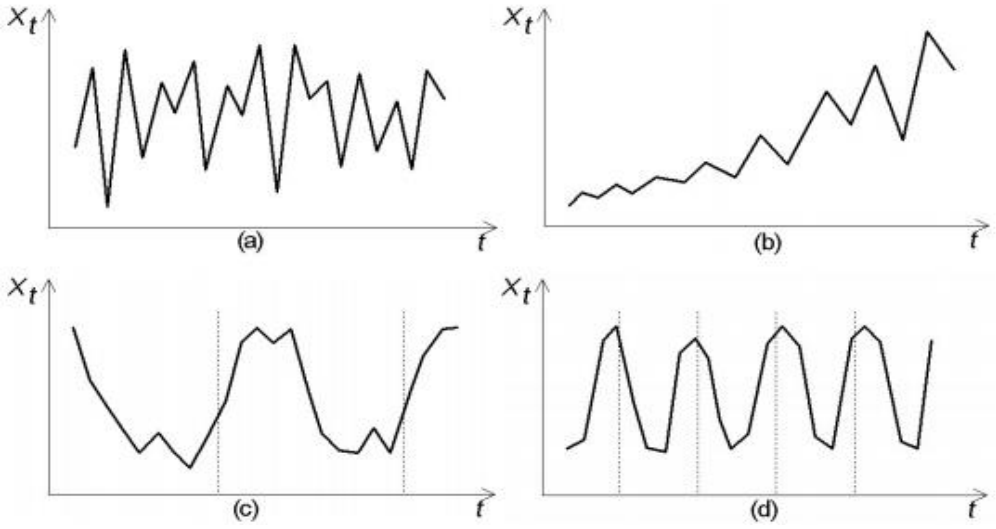

Slika 4*: a) Konstantan poces; b) Proces sa trendom; c) Serija sa cikličnim varijacijama; d) Serija sa sezonskim varijacijama*

Izvor: Kovačić, J., Z., „Analiza vremenskih serija“, Beograd, 2011., str. 4.

Bitno je naglasiti i zašto je neophodno analizirati vremenske serije. Razlozi koje novodi Kovačić su sljedeći: **deskripcija**, kao prva, ujedno i obavezna etapa, omogućava opis ključnih karakteristika vremenske serije već na osnovu njenog grafičkog prikaza, pa je često nepotrebno koristiti neke složenije statističke metode, što pojednostavljuje čitav potupak analize; **objašnjenje**, ukoliko se prilikom formiranja modela koristi veći broj serija, za objašnjenje varijacija u jednoj seriji mogu se koristiti varijacije u drugoj seriji; **prognoziranje**, na osnovu opservacija iz predhodnog perioda formira se i ocjenjuje model da bi se upotrijebio za predviđanje kretanja vremenske serije u budućnosti; i **kontrola**, koja je bitna, jer se na osnovu formiranog modela vrši prognoziranje. Ulazna serija se prilagođava radi postizanja željenog cilja.[41]

U narednim poglavljima su detaljnije obrađeni osnovni koncepti na kojima se zasniva analiza vremenskih serija, kao što su normalnost, stacionarnost i kointegracija.

2.1.1. Ispitivanje uslova normalnosti

Iz teorijskih i praktičnih razloga, normalna raspodjela je vjerovatno najvažnija raspodjela u statistici. Veliki broj klasičnih statističkih testova se zasniva na pretpostavci da podaci slijede normalnu distribuciju, koju treba ispitati prije primjene ovih testova. Prilikom formiranja modela, bilo da je u pitanju linearna ili nelinearna regresija, često se pretpostavlja da slučajna greška slijedi normalnu distribuciju.

Da bi vremenska serija imala normalnu raspodjelu vjerovatnoća (kriva u obliku zvona - ***Slika 5.***), moraju biti ispunjeni sljedeći uslovi:[42]

- vrijednosti aritmetičke sredine, medijane i modusa su jednake;
- kriva je simetrična u odnosu na aritmetičku sredinu, to znači da se 50% ukupne površine ispod krive normalne raspodjele nalazi sa lijeve strane aritmetičke sredine, a 50% sa desne strane aritmetičke sredine;
- ukupna površina ispod krive je 1 ili 100%;
- krajevi krive normalne raspodjele se protežu u beskonačnost u oba smjera i ne dodiruju niti sijeku horizontalnu osu.

[41] Kovačić, J.Z. (1995). *Analiza vremenskih serija*. Univerzitet u Beogradu, Ekonomski fakultet, str.6.
[42] Mann, P. S. (2007). *Introductory statistics*. John Wiley & Sons, pp. 276-277.

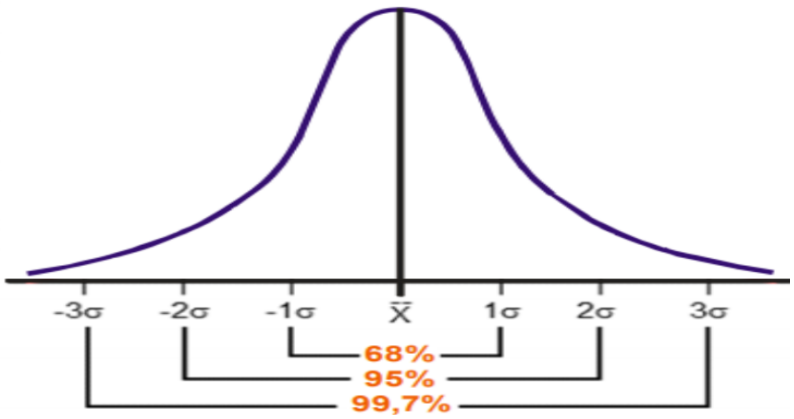

***Slika 5**: Raspodjela podataka prema empirijskom pravilu*

Izvor: Radman Funarić, M. (2018). Uvod u gospodarsku statistiku. Veleučilište u Požegi, Požega, str. 77.

Za simetričnu distibuciju (distribucija u obliku zvona, ***Slika 5.***) primjenjuju se svojstva normalne distribucije, a važi empirijsko pravilo da se svi podaci nalaze unutar tri standardne devijacije od aritmetičke sredine, pri čemu se 68% podataka nalazi unutar jedne standardne devijacije od aritmetičke sredine, 95% podataka je udaljeno dvije, a 99,7% podataka tri standardne devijacije od aritmetičke sredine.

Da bi se utvrdilo da li serija ima normalnu raspodjelu može se koristiti grafički prikaz odnosno **histogram**, kao jedan od najjednostavnijih i najčešće korišćenih načina. Na histogramu su na x-osi prikazani intervali jednake dužine koji korespondiraju frekvenciji pojavljivanja tih istih podataka na y-osi. Sa histograma se jasno vidi da li kriva, koja se formira spajanjem tačaka na x i y osi, predstavlja normalnu raspodjelu ili ne.

Ukoliko se grafički, sa preciznošću, ne može utvrditi normalna raspodjela vremenske serije, za procjenu se upotrebljava koeficijent asimetrije i koeficijent spljoštenosti (***Slika 6.***). **Koeficijent asimetrije** ili treći momenat distribucije pokazuje da li je distribucija asimetrična ulijevo ili udesno. Distribucija je asimetrična ulijevo kada je negativna vrijednost koeficijenta, a asimetrična je udesno kada je vrijednost koeficijenta asimetrije pozitivna. Vrijednost ovog koeficijenta se posmatra u odnosu na nulu, ukoliko je vrijednost trećeg momenata distribucije manja od nule to znači da je raspodjela asimetrična uljevo, a ako je veća od nule onda je asimetrična u desno.

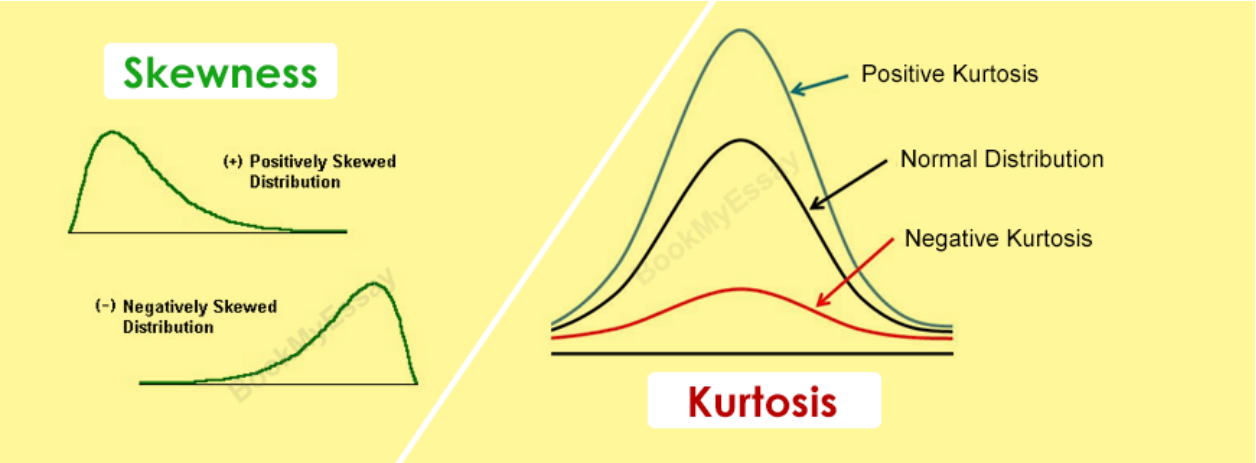

***Slika 6**: Grafički prikaz raspodjele podataka pri razičitim vrijedostima koeficijenta asimetrije (lijevo) i koeficijenta spljoštenosti (desno)*

Izvor: https://www.bookmyessay.com/skewness-and-kurtosis-assignment/

Koeficijent spljoštenosti ili četvrti momenat distribucije je parametar koji pruža informacije o raspršenosti distribucije, tj. pokazuje u kojoj mjeri su vrijednosti raspršene oko aritmetičke sredine. Ima vrijednost 3 ako je u pitanju normalna distribucija. Ukoliko je ovaj koeficijent manji od 3 onda je kriva spljoštena, a ako je veći od 3 kriva je zašiljena, odnosno vremenska serija nema normalnu raspodjelu.

2.1.2. Testiranje stacionarnosti

Ukoliko se vremenska serija kreće po ustaljenom obrascu, ne mijenjajući svoja svojstva tokom vremena, onda je ta serija stacionarna. Stacionarna vremenska serija je ona čija svojstva ne zavise od vremena u kome se serija posmatra. Serije koje imaju trend i sezonalnost nijesu stacionarne, jer upravo te osobine utiču na promjenu svojstava serije tokom vremena. Serija koja je poznata pod nazivom "bijeli šum" je nepomična, odnosno, bez obzira kada se posmatra trebalo bi da izgleda približno isto u bilo kojem trenutku. Uopšteno, stacionarna vremenska serija neće imati predvidive obrasce kretanja u dugom roku. Vremenski grafikoni će pokazati da su serije grubo horizontalne (mada je moguće i neko ciklično kretanje) sa stalnom varijansom.[43]

[43] Hyndman, R.J., & Athanasopoulos, G. (2018). *Forecasting: principles and practice*, 2nd edition, OTexts: Melbourne, Australia, Chapter 8: ARIMA models, Stationarity and Differencing., p. 291. (dostupno na linku: https://otexts.com/fpp2/)

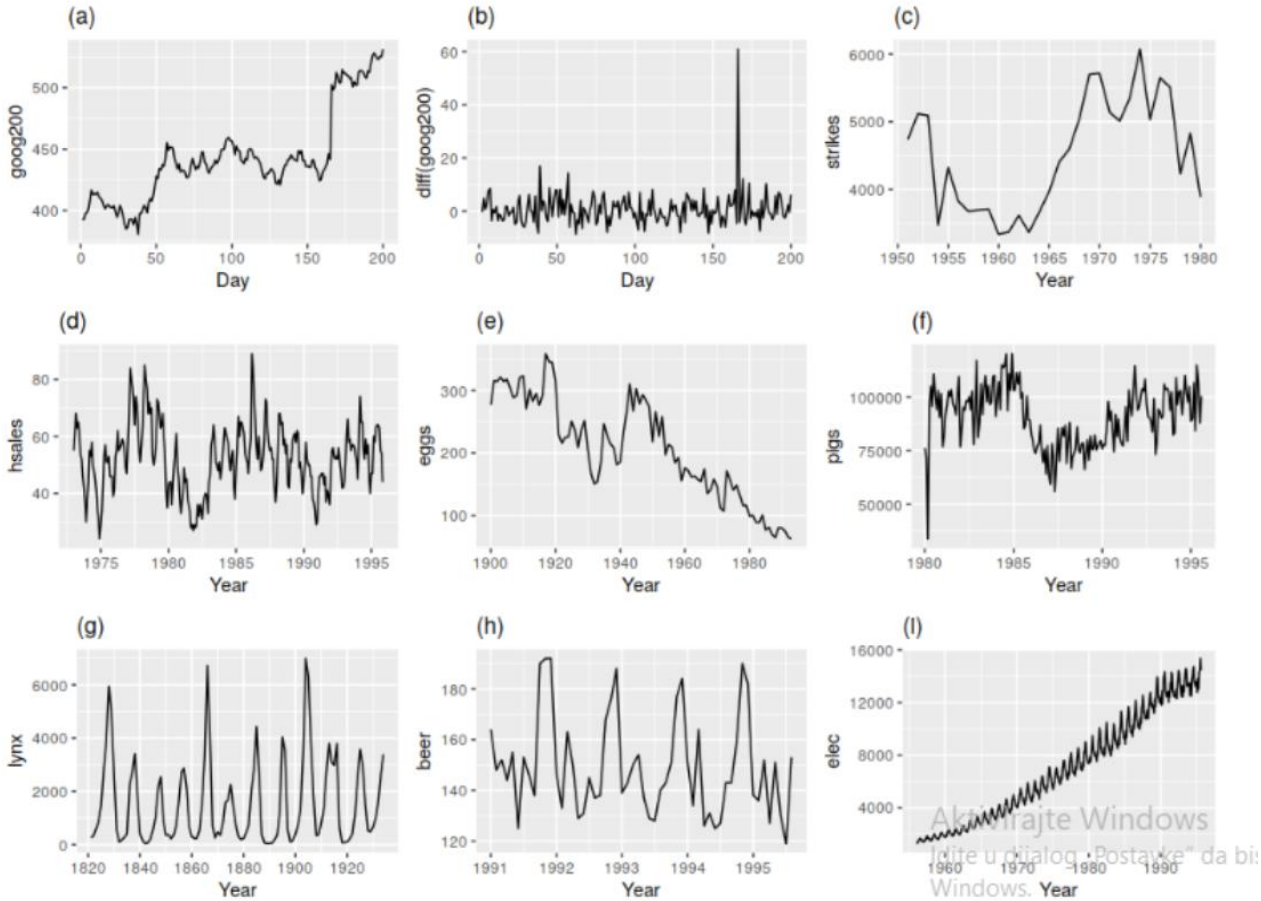

Slika 7*: Vremenske serije: (a) Cijena Google akcija 200 dana zaredom; (b) Svakodnevna promjena cijene Google akcija 200 uzastopnih dana; (c) Godišnji broj štrajkova u SAD-u; (d) mjesečna prodaja novih porodičnih kuća koje se prodaju u SAD-u; (e) Godišnja cijena desetak jaja u SAD-u (stalni dolari); (f) Mjesečno zaklane svinje u Viktoriji, Australija; (g) Godišnji ukupni ris zarobljen u oblasti rijeke McKenzie na sjeverozapadu Kanade; (h) Mjesečna proizvodnja australijskog piva; (i) Mjesečna proizvodnja električne energije u Australiji.*[44]

Izvor: Hyndman, R.J., &Athanasopoulos, G., "Forecasting: principles and practice, 2nd edition, Melbourne, Australia, 2018., p. 292.

Na ***Slici 7.*** su prikazane vremenske serije i njihovo ponašanje tokom određenog vremenskog perioda, u nastavku teksta je ispitano da li su serije stacionarne ili ne. Očigledna sezonalnost isključuje serije (d), (h) i (i). Trendovi i promjene nivoa isključuju serije (a), (c), (e), (f) i (i). Sve veća varijansa takođe isključuje (i). To ostavlja samo (b) i (g) kao stacionarne serije.[45] Kod stacionarne vremenske serije aritmetička sredina i varijansa su konstantne tokom vremena, dok kovarijansa zavisi isključivo od vremenskog razmaka u kome se razmatraju promjenljive a ne od vremenskog trenutka.

[44] Ibd., str. 292.
[45] Ibd., str. 295-297.

Postoje dva koncepta stacionarnosti:[46]

1. **Koncept stroge stacionarnosti** (striktna ili jaka stacionarnost ili stacionarnost u užem smislu). Serija je strogo stacionarna ako ima konstantnu očekivanu vrijednost na cijelom uzorku, konstantnu varijansu i konstantnu kovarijansu.
2. **Koncept slabe stacionarnosti** (kovarijantna stacionarnost ili stacionarnost u širem smislu) Serija je slabo stacionarna ako zadovoljava sledeće uslove: a) $E(Xt) = \mu = const$, $t = 1,2,...$; b) $Var(Xt) = E(Xt - \mu)^2 = const$, $t =1,2,...$; c) $Cov(Xt, Xt\text{-}k) = E(Xt - \mu)(Xt\text{-}k - \mu) = \gamma(k) = \gamma k$, $t = 1,2,...$, što bi značilo da su očekivana vrijednost i varijansa konstantne dok kovarijansa nije konstantna.

U ekonomiji se analiziraju realni podaci o stopi inflacije, stopi nezaposlenosti, kamatnim stopama, čije vremenske serije često nijesu stacionarne. Da bi se konstruisao valjan model, koji se može iskoristiti za korisna predviđanja, neophodno je nestacionarne vremenske serije transformisati u stacionarne. Pod transformacijom vremenske serije se podrazumijeva: diferenciranje podataka, testiranje stacionarnosti serije reziduala iz modela, logaritmovanje podatka.[47]

Postoji veliki broj razloga za upotrebu stacionarnih vremenskih serija. Među **statističkim** se izdvajaju sljedeći: primjena standardne statističke procedure je nepouzdana u regresionoj analizi nestacionarnih vremenskih serija; ukoliko jedna serija nije stacionarna, a koristi se za ocjenjivanje modela metodom najmanjih kvadrata, dobijaju se ocjene koje su pristrasne i nekonzistentne; za nestacionarne serije ne važi normalan raspored, pa samim tim i ne važe zaključci t-testa i F-testa; kod nestacionarnih serija često se javljaju lažne regresije, odnosno regresije sa visokim vrijednostima koeficijenta determinacije. **Ekonomski razlog** za upotrebu stacionarne serije jeste to što ukoliko se javi šok u okruženju, kod nestacionarne serije on će imati dug efekat, a kod stacionarne će se brzo izgubiti.

2.1.3. Koncept kointegracije

Koncept kointegracije se odnosi na serije koje su individualno nestacionarne, ali je njihova linearna kombinacija stacionarna. Ovaj koncept je jako pimamljiv za opisivanje ekonomskih relacija s obzirom na to da su većina makroekonomskih kao i veliki broj finansijskih varijabli nestacionarne. Kointegracija se lakše može razumjeti kroz primjer vremenskih serija potrošnje i dohotka. Ove vremenske serije su najčešće nestacionarne i svaka od njih posjeduje sopstveni stohastički trend, ali se njihovo kretanje odvija u određenim granicama u smislu da se serije ne udaljavaju mnogo jedna od druge. Između njih postoji tzv. “sila privlačenja“, koja ih vuče jednu ka drugoj, a razlog za to leži u njihovom ekonomskom karakteru, potrošnja je sastavni dio dohotka.

---

[46] Mladenović Z, Nojković A. (2012). *Primenjena analiza vremenskih serija*, Centar za izdavačku delatnost Ekonomskog fakulteta u Beogradu, str. 15-16.

[47] Hyndman, R.J., & Athanasopoulos, G. (2018). *Forecasting: principles and practice,* 2nd edition, OTexts: Melbourne, Australia, pp. 295-297.

Ovo je upravo i dokaz da zajedničko kretanje nestacionarnih vremenskih serija poprima stacionarni karakter.[48]

Koncept kointegracije je suštinski dosta sličan konceptu klasičnog linearnog regresionog modela. Cilj u istraživanju je da se varijacije zavisne promjenljive objasne varijacijama tako izabranog skupa promjenljivih da neobjašnjeni dio bude sveden na minimum. Tako se isto za dvije ili više serija sa jediničnim korijenom kaže da su kointegrisane, ukoliko postoji takav stepen slaganja u njihovom kretanju, kojim se neutrališe individualna nestacionarnost i postiže stacionarnost vremenske serije dobijene njihovom linearnom kombinacijom. Odnosno, kretanje jedne nestacionarne vremenske serije se može objasniti kretanjem druge nestacionarne vremenske serije, jer se neobjašnjeni dio može smatrati stacionarnim procesom, što je i blaži uslov od onoga koji nameće klasična linearna regresija.[49]

2.2. Konstruisanje linearnog regresionog modela

Regresioni modeli su od velikog značaja za donošenje odluka i kreiranje ekonomske politike. Zasnivaju se na matematičkim jednačinama i da bi bili pravilno formulisani moraju teorijski biti dobro potkrijepljeni. Da bi se na kvalitetan način konstruisao linearni regresioni model mora se proći kroz konkretne korake kao što su: specifikacija i ocjenjivanje modela, zatim vrednovanje ocjena parametara i vrednovanje moći predviđanja. Svaka od navedenih faza će, u narednim poglavljima, biti detaljnije razrađena.

2.2.1. Specifikacija modela

Prva faza empirijskog istraživanja podrazumijeva specifikaciju ekonometrijskog modela. Specifikacija se sastoji iz:

a) Analize teorijskog fenomena. Da bi specifikacija bila pravilno izvedena neophodno je da istraživač ima predhodno znanje o matematičkoj formi i varijablama koje sačinjavaju model, ali i izvjesna očekivanja o znaku i veličini svakog parametra modela. Istraživač na osnovu ekonomske teorije dolazi do pravilno definisane hipoteze koju će da ispituje.[50]

b) Izbora matematičke forme. Jedan od modela koji se najčešće koristi u ekonometriji je jednostavni linearni regresioni model koji se može predstaviti sljedećom jednačinom:[51]

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i, \text{ gdje su}$$

Y_i – i-ta zavisna promjenljiva

[48] Mladenović, Z., & Petrović, P. (2007). *Uvod u ekonometriju*. Centar za izdavačku delatnost Ekonomskog fakulteta, str. 216.
[49] Z. Mladenović, P. Petrović, op. cit., str. 217.
[50] Jovičić, M., Dragutinović Mitrović R. (2011). *Ekonometrijski metodi i modeli*, Centar za izdavačku djelatnost Ekonomskog fakulteta u Beogradu, str. 16-19.
[51] Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: principles and practice*. OTexts, p. 128.

X_i – i-ta nezavisna promjenljiva
β_0 – odsječak ili slobodni član
β_1 – nagib
ε_i – stohastički član ili slučajna greška

Na ***Slici 6.*** grafički je prikazan jednostavni linearni regresioni model koji se sastoji od **determinističkog dijela** ($\beta_0 + \beta_1 X_i$), koji predstavlja pravu liniju pa je model linearan i **stohastičkog člana** (ε_i), kojim su obuhvaćena sva odstupanja od prave linije. To je takozvana "greška" modela[52], koja obuhvata sve ono što utiče na zavisnu promjenjlivu (Y_i), a da nije nezavisna promjenljiva (X_i).

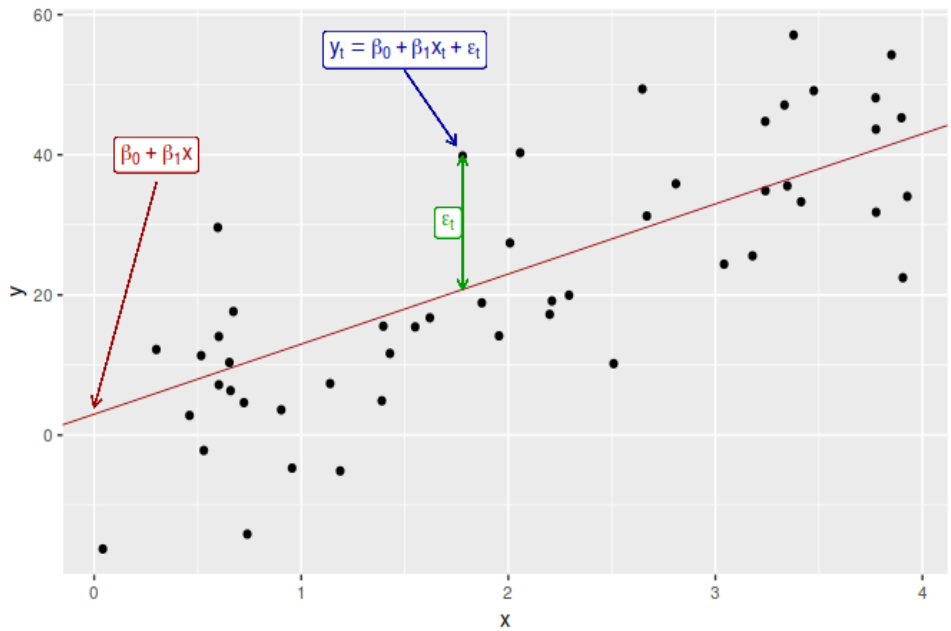

Slika 8*: Primjer podataka kojima je prilagođen model jednostavne linearne regresije*
Izvor*: Hyndman, R. J., & Athanasopoulos, G. (2018). Forecasting: principles and practice. OTexts., p.128.*

Veza između zavisne (Y_i) i nezavisne (X_i) promjenljive je stohastička. Stohastičke veze su vrlo česte u društvenim naukama, posebno u ekonomiji, i znatno su slabije od funkcionalnih veza koje su determinističke, odnosno egzaktne i karakteristične za prirodne nauke. Kako se funkcionalne veze teško mogu sresti u društvenim naukama, ovdje je istaknut značaj stohastičkih veza. Kod stohastičkih veza jednoj vrijednosti nezavisne promjenljive odgovara čitav niz mogućih vrijednosti zavisne promjenljive, pa se iz tog razloga uvodi stohastički član ili slučajna greška modela**.** Međutim, kako je kretanje slučajne greške nepredvidljivo, u cilju analiziranja ovakvog modela, uvode se određene pretpostavke.

[52] Slučajna greška se dodaje da bi obuhvatila uticaj slučajne greške mjerenja zbog nepodudaranja teorijskih koncepata i raspoloživih podataka, zatim zbog pogrešne specifikacije modela, ali i zbog mogučnosti javljanja greške usljed rada sa uzorkom.

c) Pretpostavke koje prate specifikaciju linearnog regresionog modela su: [53]

1. $E(\varepsilon_t)=0$, za sve i, (srednja vrijednost greške je jednaka nuli);
2. $E(\varepsilon_i^2)= \sigma^2$, za sve i, (konstantna zajednička varijansa);
3. $E(\varepsilon_i\varepsilon_j)=0$, za svako i, j, $i\neq j$, (nezavisnost grešaka);
4. ε: $N(0, \sigma^2)$, (greška ima normalan raspored);
5. $E(\varepsilon_i X_j)=0$, za sve i, j, (nezavisnost greške od regresora)

S obzirom na to da u ekonomiji na jednu varijablu može uticati više faktora, odnosno više nezavisnih varijabli (npr., na bruto domaći proizvod utiču: investicije, potrošnja) postoje i višestruki linearni regresioni modeli, kojima se zbog složenije strukture dodaju sljedeće pretpostavke: broj opservacija u uzorku je veći od broja parametara za ocjenjivanje i između eksplanatornih varijabli ne postoji međusobna perfektna koreliranost.[54]

2.2.3. Ocjena modela i vrednovanje ocjene modela

Nakon specifikacije modela slijedi njegovo ocjenjivanje. Ocjenjivanje modela predstavlja fazu u dobijanju rezultata i obuhvata nekoliko značajnih aktivnosti: sakupljanje podataka, ispitivanje razvojnih osobina varijabli, stepen korelacije među varijablama, odnosno multikolinearnost, testiranje stacionarnosti i kointegracije za vremenske serije, ali i izbor i primjenu ekonometrijske tehnike koja je odgovarajuća da bi se ocijenio model.[55] U ovom stadijumu se izračunavaju numeričke vrijednosti parametara modela, na osnovu podataka iz uzorka, jer je izračunavanje pomoću podataka iz populacije izvodljivo jedino ukoliko su poznate sve moguće vrijednosti promjenljivih (Y, X, ε) koje formiraju populaciju, a to je u praksi najčešće nemoguće.

Da bi se odredila numerička vrijednost nepoznatog parametra iz podataka uzorka, potrebno je definisati matematičku formulu koja se primjenjuje u opštem slučaju. Ta formula, koja se naziva ocjena, predstavlja funkciju podataka iz uzorka, a rezultat primjene te formule na podacima posmatranog uzorka, daje jedinstvenu ocjenu numeričke vrijednosti nepoznatog parametra i naziva se ocijenjena vrijednost. Metod koji se najviše upotrebljava, i koji će ovdje biti objašnjen, je metod najmanjih kvadrata koji je ujedno primijenjen i u praktičnom dijelu ovog rada. Ovim metodom se ocjene parametara regresione prave dobijaju tako što se minimizira suma kvadratnih odstupanja opservacija od regresione prave. Suma ovih odstupanja treba da je zanemarljivo mala, odnosno da se odstupanja naviše i naniže potiru, zato se minimizira suma njihovih kvadrata. Ako se jednačina ocjene regresione prave za jednostavni model specificira kao:[56]

$$\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_i \qquad (1)$$

[53] Greene, W. H. (2003). Econometric Analysis, Prentice Hall. *New Jersey*, 16, p. 42.
[54] Jovičić M., (2002). *Ekonometrijski metodi*, Beograd M. Jovičić, str. 61.
[55] Jovičić, M., Dragutinović Mitrović R. (2011). *Ekonometrijski metodi i modeli*, Centar za izdavačku djelatnost Ekonomskog fakulteta u Beogradu, str. 19.
[56] M. Jovičić, R. Dragutinović Mitrović., op. cit., str. 31.-32.

gdje su kapama označene ocijenjene vrijednosti. Izračunate vijednosti odstupanja opservacija Y_i od vrijednosti na regresionoj pravoj su ocijenjene vrijednosti greške, koje se nazivaju rezidualima:

$$e_i = Y_i - \hat{Y}_i = Y_i - \left(\hat{\beta}_0 + \hat{\beta}_1 X_i\right) \qquad (2)$$

a suma kvadrata reziduala:

$$\sum_{i=1}^{n} e_i^2 = \sum_{i=1}^{n} \left(Y_i - \hat{\beta}_0 - \hat{\beta}_1 X_i\right)^2 \quad (3)$$

je u svom minimumu kad su prvi izvodi te sume po β_0 i β_1 jednaki nuli:

$$\frac{\partial \sum e_i^2}{\partial \hat{\beta}_0} = 2\Sigma\left(Y_i - \hat{\beta}_0 - \hat{\beta}_1 X_i\right) \cdot (-1) = 0 \qquad (4)$$

$$\frac{\partial \sum e_i^2}{\partial \hat{\beta}_1} = 2\Sigma\left(Y_i - \hat{\beta}_0 - \hat{\beta}_1 X_i\right) \cdot (-X_i) = 0$$

dok su drugi izvodi pozitivni, zbog dvostrukog minusa. Iz ovih uslova dijeljenjem sa -2 i prebacujući na desnu stranu negativne članove, slijede takozvane normalne jednačine:[57]

$$\sum Y_i = n\hat{\beta}_0 + \hat{\beta}_1 \Sigma X_i$$

$$\sum Y_i X_i = \hat{\beta}_0 \Sigma X_i + \hat{\beta}_1 \Sigma X_i^2 \qquad (5)$$

čijim rješavanjem se dobijaju ocjene nepoznatih parametara:

$$\hat{\beta}_0 = \frac{\sum X^2 \Sigma Y - \sum X \Sigma XY}{n\Sigma X^2 - (\sum X)^2}; \qquad \hat{\beta}_1 = \frac{n\Sigma XY - \sum X \Sigma Y}{n\Sigma X^2 - (\sum X)^2}, \qquad (6)$$

Koristeći sljedeće karakteristike suma varijacija varijabli, gdje su malim slovima označene centrirane vrijednosti, odnosno odstupanja od aritmetičke sredine:[58]

$$\sum y_i^2 = \sum (Y_i - \bar{Y})^2 = \sum Y_i^2 - n\,\bar{Y}^2;$$

$$\sum x_i^2 = \sum (X_i - \bar{X})^2 = \sum X_i^2 - n\,\bar{X}^2;$$

$$\sum x_i y_i = \sum (X_i - \bar{X})\,(Y_i - \bar{Y}) = \sum X_i Y_i - n\bar{X}\bar{Y}, \qquad (7)$$

iz prve normalne jednačine sa dijeljenjem veličinom uzorka n dobija:

$$\bar{Y} = \beta_0 - \beta_1 \bar{X} \qquad (8)$$

A kako je prema prvoj normalnoj jednačini suma modelom ocijenjenih vrijednosti zavisne varijable jednaka sumi originalnih vrijednosti Y_i, to im je i srednja vrijednost u uzorku ista. Otuda je iz izraza jasno da je sredina ocijenjenih vrijednosti zavisne varijable u uzorku jednaka ocijenjenoj funkciji srednje vrijednosti nezavisne varijable, tj. da regresiona prava prolazi kroz tačke $(\bar{X},\bar{Y})$.

Zamjenjujući odatle vrijednost β_0 drugu normalnu jednačinu, slijedi:[59]

$$\sum X_i Y_i = n\bar{X}(\bar{Y} - \hat{\beta}_1\bar{X}) + \hat{\beta}_1 \sum X_i^2 = \sum X_i Y_i = \sum n\bar{X}\bar{Y} - \hat{\beta}_1(n\bar{X}^2 + \sum X_i^2),$$

pa je koristeći jednakost (7):

$$\hat{\beta}_1 \sum x_i^2 = \sum x_i y_i\,,$$

tako da se ocjene (6) mogu izraziti u centriranim vrijednostima varijabli:

[57] M. Jovičić, R. Dragutinović Mitrović., op. cit., str. 32.-33.
[58] M. Jovičić, R. Dragutinović Mitrović., op. cit., str. 33.
[59] M. Jovičić, R. Dragutinović Mitrović., op. cit., str. 33.

$$\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{X} \quad \text{i} \quad \hat{\beta}_1 = \frac{\sum x_i y_i}{\sum x_i^2}$$

Iz ovih izraza se može zaključiti da za jednostavni linearni model važi sljedeće: kad je srednja vrijednost nezavisne varijable jednaka nuli, ocjena konstante (odsječka) jednaka je srednjoj vrijednosti opservacije zavisne varijable; znak nagiba ($\hat{\beta}_1$) isti je kao znak kovarijanse, pa i znak koeficijenta korelacije između zavisne i nezavisne varijable.[60]

Nakon specifikacije modela i ocjene parametara bitan korak jeste i vrednovanje dobijenih ocjena parametara koje se vrši na osnovu tri grupe kriterijuma:[61]

1. **Ekonomski kriterijumi** se odnose na veličinu i znak ocjena parametara. Ekonomskom teorijom se definišu međuzavisnosti ekonomskih varijabli, pa ako se kao rezultat primjene modela na raspoložive opservacije dobije "pogrešan" znak ili veličina nekog parametra, takva se ocjena smatra nezadovoljavajućom. Međutim, treba razlikovati situacije kada se testira neka neispitana hipoteza o ekonomskom ponašanju. U toj situaciji se polazi od matematičke formulacije i postavljena hipoteza se sučeljava sa empirijskim podacima, pa se u zavisnosti od rezultata hipoteza prihvata ili odbacuje.
2. **Statistički kriterijumi** (testovi prvog reda) su najčešće statistička značajnost koeficijenta determinacije i ocjena parametara (F-test, t-test). Koeficijent determinacije predstavlja procenat varijacija zavisne promjenljive koji je objašnjen varijacijama nezavisnih promjenljivih, dok standardne greške ocjena parametara predstavljaju mjeru disperzije ocjena oko pravih vrijednosti parametara, pa se pomoću njih provjeravaju pojedinačne značajnosti regresionih parametara.
3. **Ekonometrijski kriterijum**i (testovi drugog reda) se svode na analizu reziduala i njima se ispituje ispunjenost pretpostavljenih osobina stohastičnosti i specifikacije modela. Iz tog razloga su testovi drugog reda detaljnije obrađeni u naredna tri poglavlja.

2.2.3.1. Testiranje autokorelacije

Autokorelacija predstavlja postojanje korelacije između opservacija koje su uređene u vremenu (vremenske serije) ili prostoru (podaci presjeka). U regresionoj analizi pojam autokorelacije se odnosi na postojanje korelacije između slučajnih greški, što bi značilo da je narušena jedna od pretpostavki klasičnog linearnog regresionog modela po kojoj su slučajne greške nekorelisane, tako da je njihova kovarijansa jednaka nuli. Ukoliko postoji autokorelacija u modelu to znači da kovarijansa više nije jednaka nuli i to se najčešće dešava prilikom ocjenjivanja zavisnosti na bazi podataka vremenskih serija, kada se može desiti da se efekat slučajne greške iz jednog perioda (t-1) ispolji u sljedećem periodu (t).

[60] M. Jovičić, R. Dragutinović Mitrović., op. cit., str. 33.
[61] M. Jovičić, R. Dragutinović Mitrović., op. cit., str. 21-22.

Ono što karakteriše ekonomske vremenske serije je integracija. Integracija podrazumijeva da kretanje vremenske serije u datom periodu zavisi od sopstvenog ponašanja u prethodnim periodima, što bi značilo da postoji određena korelacija između opservacija tokom vremena, a time i korelacija između slučajnih greški. Iz tog razloga pojedini podaci vremenskih serija podliježu različitim transformacijama prije nego što se publikuju, odnosno postanu javni.[62] Ukoliko se koristi metoda najmanjih kvadrata uz prisustvo autokorelacije, posljedice su sljedeće: ocjene parametara su nepristrasne i neefikasne, ocjena varijanse slučajne greške je pristrasna, koeficijent determinacije nije valjan pokazatelj kvaliteta regresije, rezultati t i F testa su pristrasni i nepouzdani, intervali povjerenja su neprecizni a predviđanje nepouzdano.[63]

Jedan od načina testiranja autokorelacije je testiranje uz pomoć grafičkog prikaza. Na ***Slici 9.*** su prikazane serije podataka koje svjedoče o postojanju i nepostojanju autokorelacije, pa tako pod *(a)* postoji problem pozitivne autokorelacije, odnosno rezidule karakteriše periodična promjena tokom vremena. Pod *(b)* je grafički prikazan primjer negativne autokorelacije, serija se kreće "cik-cak", što bi značilo da reziduali naizmjenično mijenjaju znak. I pod *(c)* problem autokorelacije ne postoji.

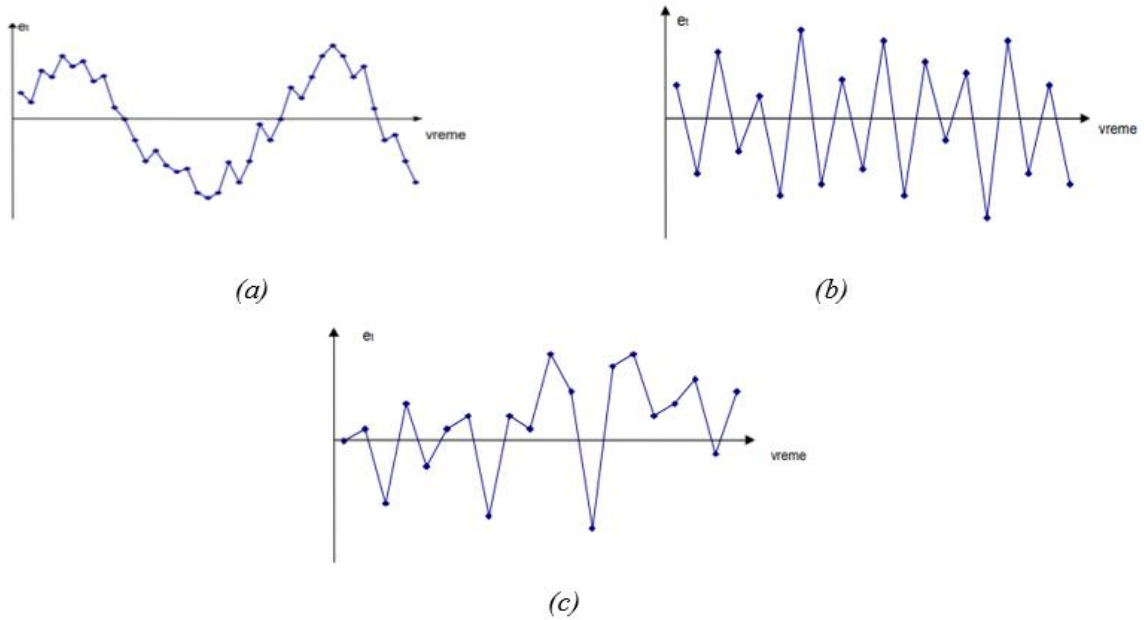

Slika 9*: (a) pozitivna autokorelacija; (b) negativna autokorelacija; (c) ne postoji autokorelacija*

Izvor: Z. Mladenović, dostupno na: *http://avs.ekof.bg.ac.rs/OEkonometrije/materijal/2019/glava8.2.pdf*

Statistički testovi koji se koriste za otkrivanje autokorelacije su *Durbin-Watson*-ov i *Breusch Godfrey* test. Ovdje će biti objašnjen postupak dokazivanja postojanja autokorelacije na osnovu *Durbin-Watson*-ovog testa (*Durbin-Watson* - DW). Vrijednost DW statistike se kreće u intervalu

[62] Mladenović, Z., & Petrović, P. (2007). *Uvod u ekonometriju*. Centar za izdavačku delatnost Ekonomskog fakulteta., str. 178.-179.

[63] Z. Mladenović, P. Petrović, op. cit., str. 183.-184.

od 0 do 4, pa što je vrijednost bliža nuli to je veća mogućnost da postoji pozitivna autokorelacija, a ukoliko je vrijednost DW statistike bliža 4 onda je u pitanju negativna autokorelacija. Ako je vrijednost DW statistike blizu 2, problem autokorelacije ne postoji. Polazi se od nulte hipoteze (H_0): autokorelacija ne postoji, koja stoji nasuprot alternativne (H_1): autokorelacija postoji. Za formalno testiranje neophodna je upotreba odgovarajućih kritičnih vrijednosti koje zavise kako od broja opservacija tako i od broja objašnjavajućih promjenljivih u polaznom modelu.[64]

2.2.3.2. Testiranje heteroskedastičnosti

Pojam heteroskedastičnosti implicira da je varijansa slučajne greške različita za razne vrijednosti nezavisne promjenljive. Heteroskedastičnost se može objasniti na primjeru dohotka (kao nezavisne promjenljive) i prosječnog nivoa štednje (kao zavisne promjenljive). Sa rastom dohotka povećava se i prosječni nivo štednje, pa varijansa štednje oko srednje vrijednosti ostaje nepromijenjena za različite vrijednosti dohotka i tada su slučajne greške homoskedastične. Kada varijansa nije konstantna već se povećava sa rastom dohotka, greške su heteroskedastične, što bi značilo da slučajna greška ne ostvaruje jednak stepen rasijavanja oko svoje srednje vrijednosti za različite nivoe objašnjavajuće, odnosno nezavisne promjenljive. Pri nižim nivoima dohotka, postoji manja mogućnost za štednju, nego pri višim nivoima dohotka. Domaćinstva sa nižim dohotkom nemaju veliki prostor za štednju pa je nivo njihove štednje približno isti. Kako se dohodak povećava mogućnosti za štednju su veće pa su i razlike u nivou štednje izraženije. U takvim situacijama dolazi do rasta varijabiliteta slučajne greške, odnosno do heteroskedastičnosti.[65]

Kada je prisutna heteroskedastičnost ocjene su nepristrasne, nemaju minimalnu varijansu (odnosno neefikasne su), ocjena varijanse slučajne greške potcjenjuje stvarnu varijansu, intervali povjerenja i testovi bazirani na ocjeni varijanse slučajne greške su nepouzdani.[66]

Heteroskedastičnost se testira pomoću *Goldfeld-Quandt*-ovog, *Breusch-Pagan*-ovog, *Spearman*-ovog i *Glejser*-ovog testa. Ovdje će biti objašnjen postupak sprovođenja *Glejser*-ovog testa. Primjena *Glejser*-ovog testa ne zahtijeva apriorno poznavanje prirode heteroskedastičnosti, već se do nje dolazi u toku samog testiranja i to tako što se iz ocijenjene polazne regresije računaju reziduali e_i. Ocjenjuju se sljedeće regresije: $/e_i/ = \sigma_0 + \sigma_1 X_i^h + greška$, parametru h najčešće se dodjeljuju vrijednosti: 1, -1 i ½. Testira se statistička značajnost ocjene parametra σ_1 primjenom t-testa, zatim se upoređuju koeficijenti determinacije dobijeni za različite vrijednosti h. Statistička značajnost ocjene σ_1 povlači sa sobom zaključak o postojanju heteroskedastičnosti. Sam karakter

[64] Z. Mladenović, P. Petrović, op. cit., str. 186.
[65] Z. Mladenović, P. Petrović, op. cit., str. 165.-166.
[66] Z. Mladenović, P. Petrović, op. cit., str. 169.

heteroskedastičnosti određuje se prema regresiji sa najvećom vrijednosti koeficijenta determinacije.[67]

2.2.3.3. Testiranje multikolinearnosti

Postojanje multikolinearnost predstavlja narušavanje jedne od pretpostavki na kojima se zasniva linearni regresioni model i javlja se kada su dvije ili više nezavisnih varijabli u regresionom modelu korelisane, otuda i zaključak da se može javiti samo kod višestruke regresije. U pitanju je statistička pojava koja i kada nije posebno izražena može da dovede do velikih problema. S obzirom na to da nastaje u okviru određenog uzorka, a ne u osnovnom skupu, postoji mogućnost njenog ukljanjanja promjenom analiziranog uzorka. Može se otkloniti i povećanjem obima uzorka, transformacijom polaznih promjenljivih ili izostavljanjem objašnjavajućih promjenljivih koje su njen uzrok. S obzirom na to da se često i ne postavlja pitanje o postojanju multikolinearnosti (jer se podrazumijeva da postoji) pristupa se utvrđivanju njene jačine i za to se koristi faktor rasta varijanse (engl. *Variance Inflation Factors – VIF*). Dobija se softverski, što će biti pokazano u praktičnom dijelu rada, a u slučaju perfektne multikolinearnosti nije ga moguće izračunati. Teorijski, kada promjenljive nisu korelisane onda je njegova vrijednost 1. Ukoliko se kreće u intervalu od 1 do 5 onda postoji umjerena korelacija, a ako je vrijednost *VIF*-a veća od 5 postoji visoka koreliranost ispitivanih nezavisnih varijabli.[68]

2.2.4. Izbor odgovarajućeg modela

Svi do sad pomenuti testovi zajednički služe da se donese zaključak o izboru odgovarajućeg modela. Ukoliko je narušena neka od pretpostavki klasičnog lineranog regresionog modela, bilo da je u pitanju postojanje autokorelacije, heteroskedastičnosti ili multikolinearnosti teži se da se one otklone. Takođe, ukoliko analizirane vremenske serije nemaju normalan raspored ili su nestacionarne teži se njihovom „transformisanju” u stacionarne.

Sve se radi u cilju dobijanja što boljeg modela, sa parametrima koji su statistički značajni i varijablama koje pokazuju međusobnu zavisnost kao i u polaznom, teorijskom modelu. Teži se da koeficijent determinacije (R^2), čija se vrijednost kreće u rasponu od 0 do 1, bude što bliži jedinici. S obzirom na to da koeficijent determinacije pokazuje procenat ukupne varijacije zavisne varijable koja je objašnjena regresijom, poželjno je da taj stepen bude što veći, pa će finalno biti izabran model koji zadovoljava sve prethodne uslove i koji pri tom ima najveću vrijednost koeficijenta determinacije. Mora se obratiti posebna pažnja kada se obrađuju empirijski podaci, jer se u praksi rijetko dešava da postoji traženi, „idealni” model. Suštinski, to i nije bitno koliko je značajno da istraživanje bude valjano sprovedeno a rezultati pravilno interpretirani.

---

[67] Z. Mladenović, P. Petrović, op. cit., str. 172.-173.
[68] Daoud, Jamal. (2017). *Multicollinearity and Regression Analysis*. Journal of Physics: Conference Series. p. 949.

2.3. Predviđanje linearnim regresionim modelom

Nakon izbora odgovarajućeg modela sljedeći, a ujedno i posljednji korak, u primijenjenom ekonometrijskom istraživanju, je predviđanje i vrednovaje moći predviđanja modela. Ovaj korak je jako bitan, jer predstavlja praktičnu primjenu ocijenjenog modela pa može poslužiti u kreiranju ekonomske politike (npr. predviđanje stope inflacije, stope nezaposlenosti, stranih direktnih investicija, kamatne stope i sl.).

Ispitivanje treba da odgovori na pitanje da li ocijenjeni model važi samo za slučajeve unutar uzorka korišćenog za njegovo ocjenjivanje ili se može smatrati da važi i izvan uzorka čije prosječne varijacije odslikava. Postoje dva osnovna načina da se ustanovi moć predviđanja: 1) korišćenjem ocjene modela za period koji nije uključen u uzorak i određivanjem statističke značajnosti razlika u varijacijama između tako prognoziranih i stvarno realizovanih vrijednosti relevantne ekonomske veličine; 2) ocjenjivanjem modela na osnovu proširenog uzorka i testiranje razlike, jer će se tako dobijene ocjene nužno razlikovati od ocjena na osnovu prvobitnog uzorka. Međutim, treba imati na umu i da bez obzira na to što model zadovoljava ekonomske, statističke i ekonometrijske kriterijume vrednovanja ocjena, moguće je da ima slabu moć predviđanja, pa kao takav ne može da se koristi u svrhe predviđanja.[69]

[69] Jovičić, M., Dragutinović Mitrović R. (2011). *Ekonometrijski metodi i modeli*, Centar za izdavačku djelatnost Ekonomskog fakulteta u Beogradu, str. 22.-23.

3. EMPIRIJSKA ANALIZA EKONOMETRIJSKOG MODELA FILIPSOVE KRIVE U CRNOJ GORI

***Marty McFly**: Zvuči prilično teško.*
***Dr. Emmett Brown**: Težina nema nikakve veze s tim.*
(Citat iz filma *Povratak u budućnost,* 1985)

Cilj ovog dijela istraživačkog rada jeste da se, na osnovu empirijskih podataka o stopi inflacije i stopi nezaposlenosti, dokaže da li je za crnogorsko tržiste model Filipsove krive relevantan kao i da li može poslužiti za predviđanje stope inflacije, u cilju njegove upotrebe za donošenje važnih makroekonomskih odluka. Kvantitativna međuzavisnost između stope inflacije i stope nezaposlenosti je utvrđena uz pomoć regresione analize, koristeći metod najmanjih kvadrata (OLS), i *Granger*-ovog testa kauzalnosti. Bazu podataka, preuzetih sa sajta Centralne banke Crne Gore (u nastavku teksta: CBCG), čine: podaci o mjesečnim stopama inflacije i stopama nezaposlenosti u periodu od januara 2008. do decembra 2018. godine. CBCG dobija podatke o stopi inflacije od Uprave za statistiku (Monstat), dok podatke o broju nezaposlenih i zaposlenih preuzima od Zavoda za zapošljavanje Crne Gore (ZZZCG) i Monstata. U daljem istraživanju uzorak je produžen do januara 2022. godine, odnosno do perioda posljednjih dostupnih podataka.

3.1. Grafički prikaz i deskriptivna statistika

U nastavku rada, posmatra se inverzan odnos između stope inflacije, koja ima ulogu zavisne varijable, i stope nezaposlenosti kao nezavisne varijable. Iz tog razloga se kao prvi korak sprovodi ispitivanje normalosti i stacionarnosti vremenskih serija, koje se koriste za formiranje modela.

Stopa inflacije se obračunava preko Indeksa potrošačkih cijena (eng. Consumer price index - CPI).[70] Indeks potrošačkih cijena (CPI) je pokazatelj prosječne promjene cijena svih proizvoda i usluga koje domaćinstva koriste u svrhu potrošnje. Pored toga što služi kao mjera inflacije može se koristiti: za usklađivanje cijena rada u privatnim ugovorima; za usklađivanje zarada, penzija, socijalnih davanja, budžeta itd; kao deflator u nacionalnim računima.[71]

Na ***Grafiku 2*** je predstavljeno kretanje stope inflacije u periodu od januara 2008. do decembra 2018. godine. Primjetno je da ne postoje značajna kolebanja stope inflacije i da se njeno kretanje u posmatranom periodu može smatrati stabilnim, bez tendencije pokazivanja rastućeg ili

[70] Od januara 2008. godine MONSTAT mijenja način izračunavanja stope inflacije koristeći Indeks potrošačkih cijena, dok od januara 2009. godine u potpunosti prestaje sa objavljivanjem Indeksa troškova života i Indeksa cijena na malo, koji su ranije bili upotrebljavani za izračunavanje stope inflacije.
[71] Dostupno na linku: https://www.monstat.org/cg/page.php?id=26&pageid=26

opadajućeg trenda. Cilj Evropske Centralne Banke (ECB) je da stopa po kojoj se cijene mijenjaju tokom vremena - stopa inflacije - ostane niska, stabilna i predvidljiva; 2% u srednjem roku.[72] CBCG je uspješno održavala stopu inflacije na željenom nivou. Plava linija, koja pokazuje kretanje stope inflacije za posmatrani period, nije prešla 2%. Istovremeno, nije došlo ni do deflacije, na *Grafiku 2.* se može vidjeti da vrijednosti nisu stigle ni do -1%.

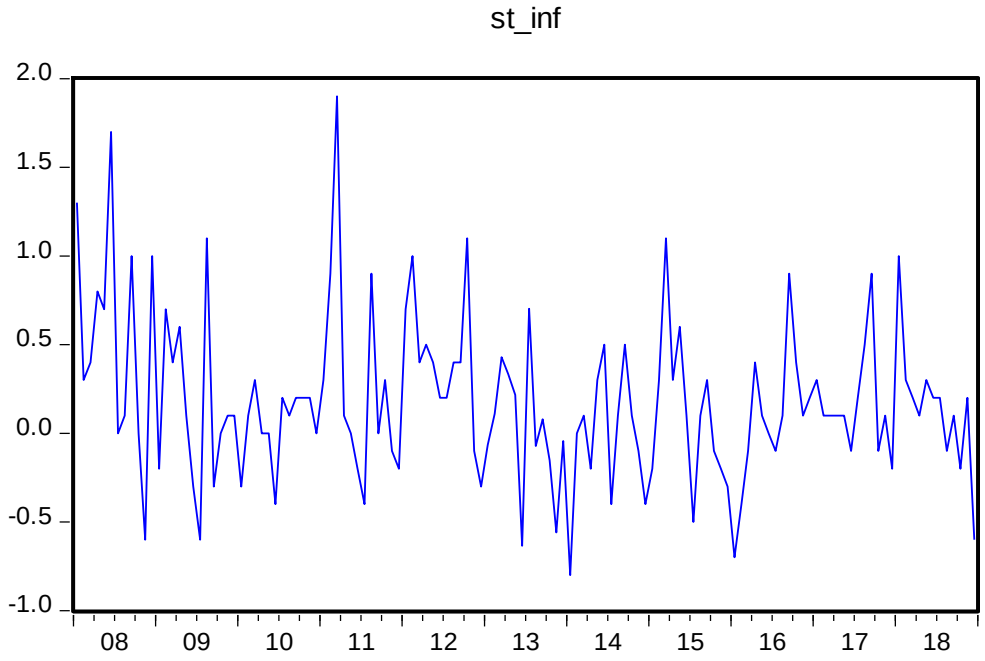

***Grafik 2**: Kretanje stope inflacije u periodu od januara 2008. do decembra 2018. godine*

Pored grafičkog prikaza, bitno je prikazati sumarne pokazatelje vremenske serije. Cilj primjene sumarnih pokazatelja je sagledavanje empirijske raspodjele date vremenske serije. Da bi bolje upoznali karakteristike vremenske serije stopa inflacije, treba je predstaviti deskriptivnom statistikom i histogramom. Kod serije koja predstavlja stopu inflacije (st_inf) dobijaju se sljedeći rezultati (***Grafik 3***):

[72] https://www.ecb.europa.eu/ecb/educational/hicp/html/index.en.html (datum pristupa: 15.02.2022.)

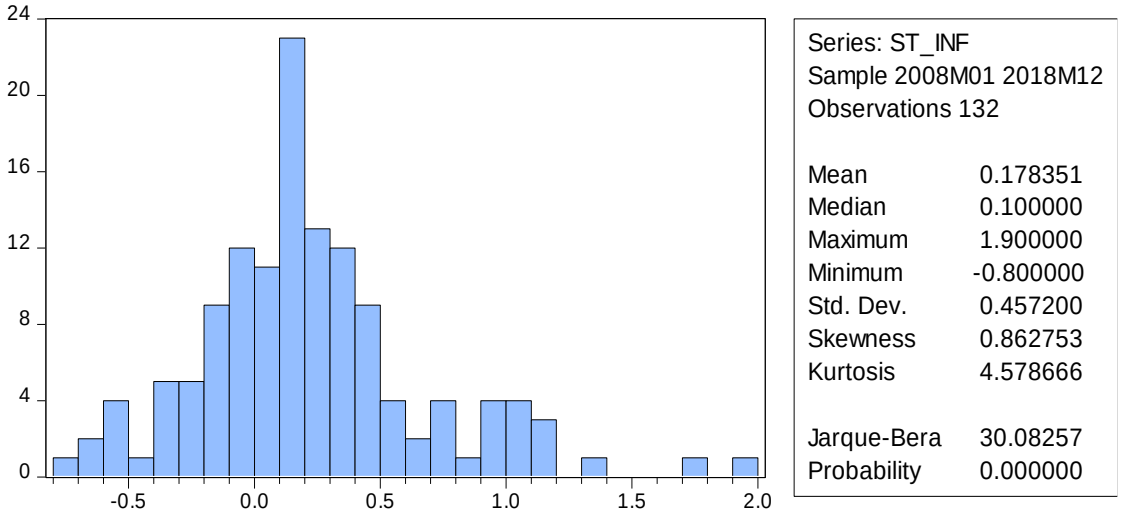

***Grafik 3**: Histogram stope inflacije sa pratećom deskriptivnom statistikom*

Uzorak ima 132 observacije. Srednja (očekivana) vrijednost (odnosno **aritmetička sredina**) iznosi približno 0,178%. Kako medijana dijeli seriju na dva dijela, 50% observacija se nalazi iznad vrijednosti 0,1% dok je preostalih 50% observacija ispod vrijednosti 0,1%. **Maksimalna vrijednost** stope inflacije za posmatrani period iznosi 1,9%, dok je **minimalna vrijednost** -0,8%.

Standardna devijacija, kao jedna od ključnih mjera varijabilnosti, koja ukazuje u kojoj mjeri prosječne vrijednosti u prosjeku odstupaju od aritmetičke sredine, iznosi 0,4572, što ukazuje na to da odstupanja podataka od prosječnih vrijednosti nisu velika, niti značajna.

Skewness (treći momenat distribucije, α_3) predstavlja koeficijent asimetrije koji pokazuje da li je distribucija asimetrična ulijevo ili udesno, i iznosi 0,862753. Dakle, vrijednost koeficijenta asimetrije je pozitivna što znači da je serija stopa inflacije asimetrična udesno. **Kurtosis** je koeficijenat spljoštenosti, odnosno parametar koji pruža informacje o rasprostranjenosti distribucije, tj. govori o tome u kojoj mjeri su vrijednosti rasprostranjene oko aritmetičke sredine. Ovo je četvrti momenat distribucije (α_4) i ima vrijednost 3 ako je u pitanju normalna distribucija. Vrijednost koeficijenta spljoštenosti iznosi 4,578666, to znači da je distribucija zašiljena, ali isto tako da njeno odstupanje od normalne distribucije nije veliko.

Konačnu odluku o normalnosti distribucije se donosi na osnovu pripadajuće **vjerovatnoće** za *Jarque-Bera* (JB) statistiku. Polazna hipoteza ovog testa tvrdi da posmatrana serija ima normalnu raspodjelu ($\alpha_3=0$ i $\alpha_4=3$), dok se alternativnom hipotezom tvrdi da serija nema normalnu raspodjelu ($\alpha_3\neq0$ i $\alpha_4\neq3$). Na osnovu vjerovatnoće JB statistike koja iznosi 0% zaključuje se da je procenat greške koja se pravi odbacivanjem polazne hipoteze 0%. Dakle, serija stopa inflacije nema normalan raspored.

S obzirom na to da ne postoje podaci o stopi nezaposlenosti, bilo je neophodno izračunati je na osnovu sljedeće formule:

st_n = (br_n/ukupan_br_rss)*100

st_n - stopa nezaposlenosti
br_n - broj nezaposlenih
ukupan_br_rss - ukupan broj radno-sposobnog stanovništva (podatak o ukupnom broju radno sposobnog stanovništva se dobija kada se sabere broj nezaposlenih i broj zaposlenih stanovnika).

Isti postupak se sprovodi i za analizu serije stopa nezaposlenosti. Na ***Grafiku 4*** se ne primjećuju veće promjene u kretanju stope nezaposlenosti, čak i neznatan rast nezaposlenosti u periodu 2016. i 2017. godine, ponovo opada 2018. godine. Primjetno je i da je u periodu svjetske ekonomske krize (2008-2009) stopa nezaposlenosti opadala sve dok nije dostigla najnižu vrijednost u prvom kvartalu 2010. godine, što bi značilo da je nakon krize počela blago da raste.

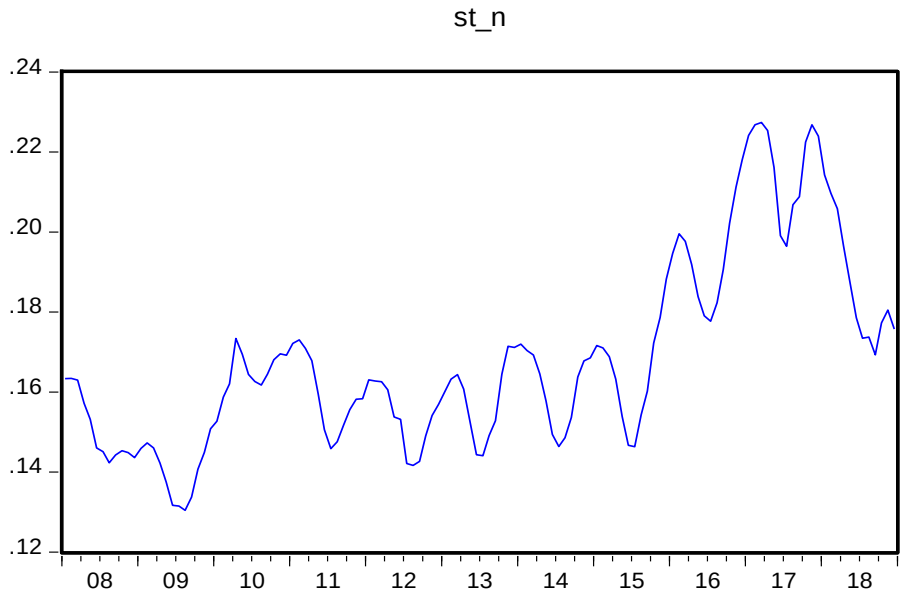

Grafik 4*: Kretanje stope nezaposlenosti u periodu od januara 2008. do decembra 2018. godine*

Uz pomoć deskriptivne statistike, na isti način kao i vremenska serija stopa inflacije, biće analizirana serija stopa nezaposlenosti.

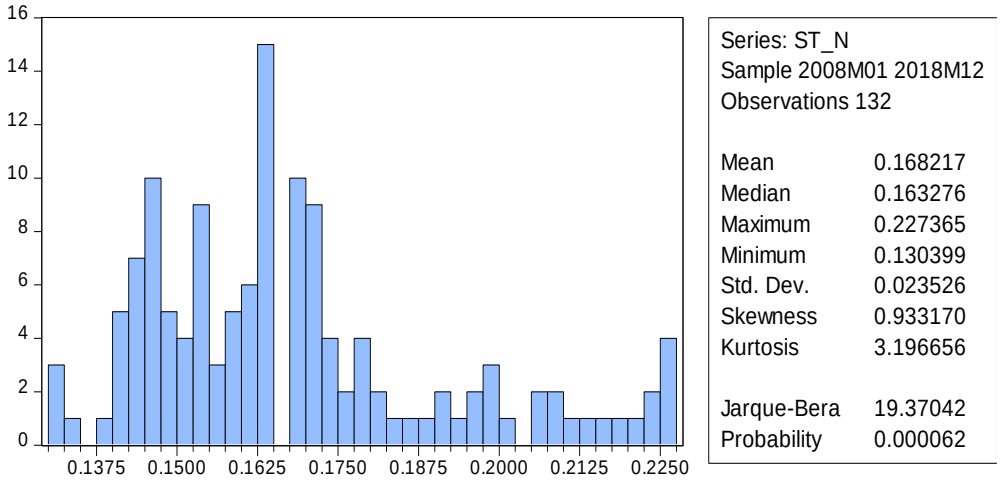

***Grafik 5**: Histogram stope nezaposlenosti sa pratećom deskriptivnom statistikom*

Na osnovu histograma (***Grafik 5***), može se zaključiti da stopa nezaposlenosti nema normalan raspored (jer nema oblik „zvona“). Maksimalna stopa nezaposlenosti je iznosila 22,73%, dok je minimalana bila 13,039%. Prosječna stopa nezaposlenosti je iznosila 16,821%. Medijana iznosi 16,327% odnosno, 50% serije se nalazi ispod, a 50% iznad vrijednosti 16,327%. Vrijednost standardne devijacije iznosi 0,023526 i svjedoči da prosječna odstupanja podataka od srednje vrijednosti nijesu značajna.

Treći momenat distribucije je pozitivan i iznosi 0,93317, pa je serija asimetrična udesno. Četvrti momenat distribucije iznosi 3,196656, odnosno distribucija je vrlo malo zašiljenija od normalne.

Jarque-Bera (JB) test će nam poslužiti za provjeru normalnosti distribucije. Sa vjerovatnoćom od 0% dolazimo do zaključka da serija stopa nezaposlenosti nema normalan raspored.

3.2. Ispitivanje stacionarnosti vremenskih serija

Stacionarnost je jako bitna osobina vremenskih serija koja podrazumijeva da su srednja vrijednost i varijansa konstantne tokom vremena, odnosno označava seriju koja se kreće po prepoznatljivoj putanji.

U nastavku rada ispituje se stacionarnost vremenske serije stopa inflacije, koja je označena sa st_inf. Stacionarnost vremenske serije stopa inflacije biće testirana pomoću testa jediničnog korijena (*Unit Root Test*), koji se zasniva na autoregresionom modelu prvog reda AR(1). Ocjenjuje se model kojim se vrijednost u trenutku *t* objašnjava vrijednošću iste serije iz prethodnog perioda, odnosno *t-1* perioda.

$$st_inf_t = \rho * st_inf_{t-1} + \varepsilon_t$$

Ukoliko je vrijednost ρ približno jednaka jedinici (ρ≈ 1), tada se očekuje da će i formalni test potvrditi postojanje jediničnog korijena, u suprotnom kada je ρ ≤ 1, formalni test će pokazati da je serija stacionarna. U ***Tabeli 1*** je predstavljen model.

***Tabela 1**: Ispitivanje stacionarnosti serije stopa inflacije*

Dependent Variable: ST_INF
Method: Least Squares
Sample (adjusted): 2008M02 2018M12
Included observations: 131 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
ST_INF(-1)	**0.247852**	0.083019	2.985502	**0.0034**

R-squared	-0.071166	Mean dependent var	0.169789
Adjusted R-squared	-0.071166	S.D. dependent var	0.448206
S.E. of regression	0.463880	Akaike info criterion	1.309223
Sum squared resid	27.97400	Schwarz criterion	1.331171
Log likelihood	-84.75408	Hannan-Quinn criter.	1.318141
Durbin-Watson stat	2.048734		

U ***Tabeli 1***, koeficijent uz varijablu stopa inflacije iz prethodnog perioda iznosi 0.247852, što je bliže nuli, pa se može očekivati da je serija stopa inflacije stacionarna. Kako bi se izabrao odgovarajući test jediničnog korijena, da bi se utvrdila stacionarnost, sprovodi se ispitivanje postojanja problema autokorelacije i heteroskedastičnosti u AR(1) modelu stope inflacije. Mogu se javiti sljedeći slučajevi:

1. Nema autokorelacije i nema heteroskedastičnosti, stacionarnost serije se može provjeriti *Dickey Fuller*-ovim testom;
2. Ima autokorelacije, nema heteroskedastičnosti, tada se stacionarnost testira uz pomoć proširenog *Dickey Fuller*-ovog testa (*engl. Augmented Dickey Fuller* - ADF);
3. Nema autokorelacije, ima heteroskedastičnosti, koristi se *Philips-Pheron*-ov test (a može i ADF);
4. Ima autokorelacije i ima heteroskedastičnosti stacionarnost se testira proširenim *Dickey Fuller*-ovim testom.

U prvom koraku se sprovodi testiranje autokorelacije *Breusch-Godfrey Serial Correlation LM* testom, a rezultati se nalaze u ***Tabeli 2.***

***Tabela 2**: Breusch-Godfrey Serial Correlation LM Test za stopu inflacije*

Breusch-Godfrey Serial Correlation LM Test:

F-statistic	0.661504	Prob. F(2,128)	0.5178
Obs*R-squared	**0.000000**	**Prob. Chi-Square(2)**	**1.0000**

U testu iz ***Tabele 2***, nulta hipoteza glasi (H_0): nema autokorelacije višeg reda, dok je alternativna (H_1): postoji autokorelacija višeg reda. Rezultati *Breusch-Godfrey Serial Correlation LM Test,* uz vjerovatnoću 100% i uz rizik greške 10%, ukazuju da u modelu ne postoji autokorelacija grešaka višeg reda.

Drugi korak, nakon testiranja autokorelacije, jeste testitanje heteroskedastičnosti *Breusch-Pagan-Godfrey* testom (***Tabela 3***). Polazna hipoteza ovog testa tvrdi da ne postoji problem heteroskedastičnosti u modelu. Na osnovu pripadajuće vjerovatnoće od 88,90% zaključuje se da problem heteroskedastičnosti u modelu ne postoji.

Tabela 3*: Breusch-Pagan Godfrey test heteroskedastičnosti za stopu inflacije*

Heteroskedasticity Test: Breusch-Pagan-Godfrey

F-statistic	0.019188	Prob. F(1,129)	0.8900
Obs*R-squared	**0.019483**	**Prob. Chi-Square(1)**	**0.8890**
Scaled explained SS	0.035869	Prob. Chi-Square(1)	0.8498

S obzirom na to da u modelu ne postoji ni problem autokorelacije, a ni problem heteroskedastičnosti, testiranje stacionarnosti će biti izvršeno *Dickey Fuller*-ovim testom (***Tabela 4***).

Tabela 4*: Dickey Fuller-ov test stacionarnosti za seriju stopa inflacije*

Null Hypothesis: ST_INF has a unit root
Exogenous: Constant
Lag Length: 1 (Automatic - based on SIC, maxlag=1)

		t-Statistic
Elliott-Rothenberg-Stock DF-GLS test statistic		**-2.330345**
Test critical values:	1% level	-2.582872
	5% level	-1.943304
	10% level	**-1.615087**

Na osnovu kritičnih vrijednosti (-1,615087) i na osnovu vrijednosti t-testa (-2,330345), uz rizik greške od 5% i 10%, zaključak je da je serija stopa inflacije stacionarna.

Isti postupak će biti sproveden i za seriju stopa nezaposlenosti. Ocjenjuje se autoregresioni model stope nezaposlenosti:

$$st_n_t = \rho * st_n_{t-1} + \varepsilon_t.$$

Ocjena ovog modela je data u ***Tabeli 5.***

***Tabela 5**: Ispitivanje stacionarnosti serije stopa nezaposlenosti*

Dependent Variable: ST_N
Method: Least Squares
Sample (adjusted): 2008M02 2018M12
Included observations: 131 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
ST_N(-1)	**1.000008**	0.002904	344.3717	**0.0000**

R-squared	0.942880	Mean dependent var	0.168254
Adjusted R-squared	0.942880	S.D. dependent var	0.023613
S.E. of regression	0.005643	Akaike info criterion	-7.509060
Sum squared resid	0.004140	Schwarz criterion	-7.487112
Log likelihood	492.8434	Hannan-Quinn criter.	-7.500142
Durbin-Watson stat	0.779151		

Vrijednost koeficijenta ρ iznosi 1, što sugeriše da je serija nestacionarna. Međutim, to je potrebno provjeriti i formalnim testom. U drugom koraku se pristupa testiranju autokorelacije.

***Tabela 6**: Breusch-Godfrey Serial Correlation LM Test za stopu nezaposlenosti*

Breusch-Godfrey Serial Correlation LM Test:

F-statistic	38.83936	Prob. F(2,128)	0.0000
Obs*R-squared	49.45237	Prob. Chi-Square(2)	**0.0000**

Rezultati *Breusch-Godfrey Serial Correlation LM* testa, ukazuju da problem autokorelacije u modelu ne postoji (***Tabela 6***). Nakon testiranja autokorelacije, provjerava se prisustvo problema heteroskedastičnosti. Primjenom *Glejser*-ovog testa dobijeni rezultati su prikazani u ***Tabeli 7***.

***Tabela 7**: Glejser-ov test heteroskedastičnosti za stopu nezaposlenosti*

Heteroskedasticity Test: Glejser

F-statistic	9.485725	Prob. F(1,129)	0.0025
Obs*R-squared	**8.972982**	**Prob. Chi-Square(1)**	**0.0027**
Scaled explained SS	8.970263	Prob. Chi-Square(1)	0.0027

Na osnovu p vrijednosti koja iznosi 0,27%, zaključak je da problem heteroskedastičnosti postoji. Kada nije prisutan problem autokorelacije a javlja se problem heteroskedastičnosti, onda se za testiranje stacionarnosti može primijeniti ADF test.

***Tabela 8**: Augmented Dickey Fuller test stacionarnosti za seriju stopa nezaposlenosti*

Null Hypothesis: ST_N has a unit root
Exogenous: Constant
Lag Length: 12 (Automatic - based on SIC, maxlag=12)

		t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic		**-3.529712**	**0.0088**
Test critical values:	1% level	-3.486064	
	5% level	-2.885863	
	10% level	**-2.579818**	

Na osnovu vrijednosti t-statistike (-3,529712) i kritičnih vrijednosti (-2,579818) ADF testa, uz rizik greške od 10%, serija stopa nezaposlenosti je stacionarna, odnosno njeno kretanje je predvidljivo.

Dosadašnjim ispitivanjem serija dolazi se do zaključka da su obje serije stacionarne pa nema potrebe za njihovim diferenciranjem, niti ispitivanjem kointegracije, već se odmah pristupa specifikaciji modela.

3.3. Specifikacija modela Filipsove krive u Crnoj Gori

Originalna Filipsova kriva opisuje inverzan odnos stope inflacije i stope nezaposlenosti, pri čemu se stopa inflacije uzima kao zavisna varijabla dok je stopa nezaposlenosti nezavisna. Radi utvrđivanja zavisnosti stope inflacije od stope nezaposlenosti biće upotrijebljena regresiona analiza, odnosno klasični linearni regresioni model da bi se provjerilo da li na crnogorskom tržistu postoji inverzan odnos ove dvije važne makroekonomske varijable.

Specifikacija modela je sljedeća:

$$st_inf = \beta_1 * st_n + \varepsilon_t$$

Zavisna varijabla: ***st_inf*** – stopa inflacije
Nezavisna varijabla: ***st_n*** – stopa nezaposlenosti
ε_t – stohastički član. Rezultati ocjene modela su prikazani u ***Tabeli 9***.

***Tabela 9**: Ocjena modela st_inf = β_1*st_n + ε_t*

Dependent Variable: ST_INF
Method: Least Squares
Sample: 2008M01 2018M12
Included observations: 132

Variable	Coefficient	Std. Error	t-Statistic	Prob.
ST_N	1.024527	0.235164	4.356650	0.0000

R-squared	0.007378	Mean dependent var	0.178351
Adjusted R-squared	0.007378	S.D. dependent var	0.457200
S.E. of regression	0.458884	Akaike info criterion	1.287507
Sum squared resid	27.58521	Schwarz criterion	1.309346
Log likelihood	-83.97543	Hannan-Quinn criter.	1.296381
Durbin-Watson stat	1.655638		

U ***Tabeli 9***, na osnovu p vrijednosti (0%), dolazi se do zaključka da postoji statistički značajan efekat stope nezaposlenosti na stopu inflacije. Ukoliko se stopa nezaposlenosti poveća za 1% doći će do rasta stope inflacije, u prosjeku, za 1,024527%. Vrijednost koeficijenta determinacije (R-squared), ukazuje da je svega 0,7378% varijabiliteta stope inflacije objašnjeno varijabilitetom stope nezaposlenosti, što znači da model nije dobar za dalju analizu (čak i prilagođeni koeficijent korelacije (adjusted R-squared) ima istu vrijednost). S obzirom na to da su originalne serije stacionarne isti rezultati se dobijaju i kada se koriste njihove diference, koje su takođe stacionarne, pa se pristupa logaritmovanju originalnih serija. Na ***Grafiku 6*** je prikazana logaritmovana serija stopa nezaposlenosti i može se zaključiti da postoji velika sličnost u grafičkom prikazu sa originalnom serijom, koja je već analizirana (pogledati ***Grafik 4***).

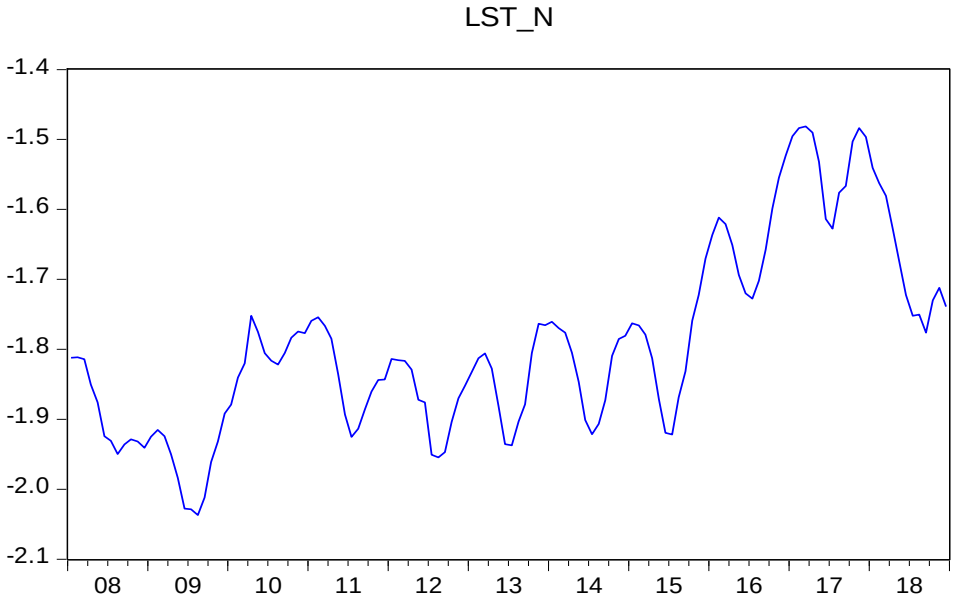

***Grafik 6**: Logaritmovana serija podataka stope nezaposlenosti*

Međutim, logaritmovanjem vrijednosti iz serije stopa inflacije dobija se drugačiji rezultat. Objašnjenje se zasniva na činjenici da stopa nezaposlenosti zavisi od broja nezaposlenih. Broj nezaposlenih ne može biti negativan, već je jednak nuli (što u relanim uslovima nije moguće), ili je to neka pozitivna vrijednost, koja manje ili više varira u zavisnosti od trenutnog stanja u ekonomiji. Iz tog razloga se dobija vrijednost logaritamske serije podataka za stopu nezaposlenosti bez prekida na grafiku, jer se logaritam od pozitivnog broja može uvijek izračunati. Kako vrijednosti serije stopa inflacije nijesu samo pozitivne, postoje mjeseci kada je stopa inflacije bila jednaka nuli ili negativna (logaritam od negativnog broja ili nule nije moguće odrediti), to će se na grafiku prikazati u vidu isprekidane linije (***Grafik 7 (a)***). Takvi prekidi ukazuju da su ti podaci izgubljeni, i da je sada broj podataka smanjen, pa je moguće da se u analizi dobije model koji nije vjerodostojan usljed nedostatka podataka.

Na ***Grafiku 7*** je prikazano rješenje problema. Kada se dobije logaritmovana serija *(a)*, izvrši se njena interpolacija *(b)* i ponovo se dobijaju podaci za svih 132 obzervacije, a na istom grafiku pod *c)* jasno se vidi plava linija koja označava logaritmovanu seriju i crvena linija koja predstavlja interpolaciju logaritamske serije.

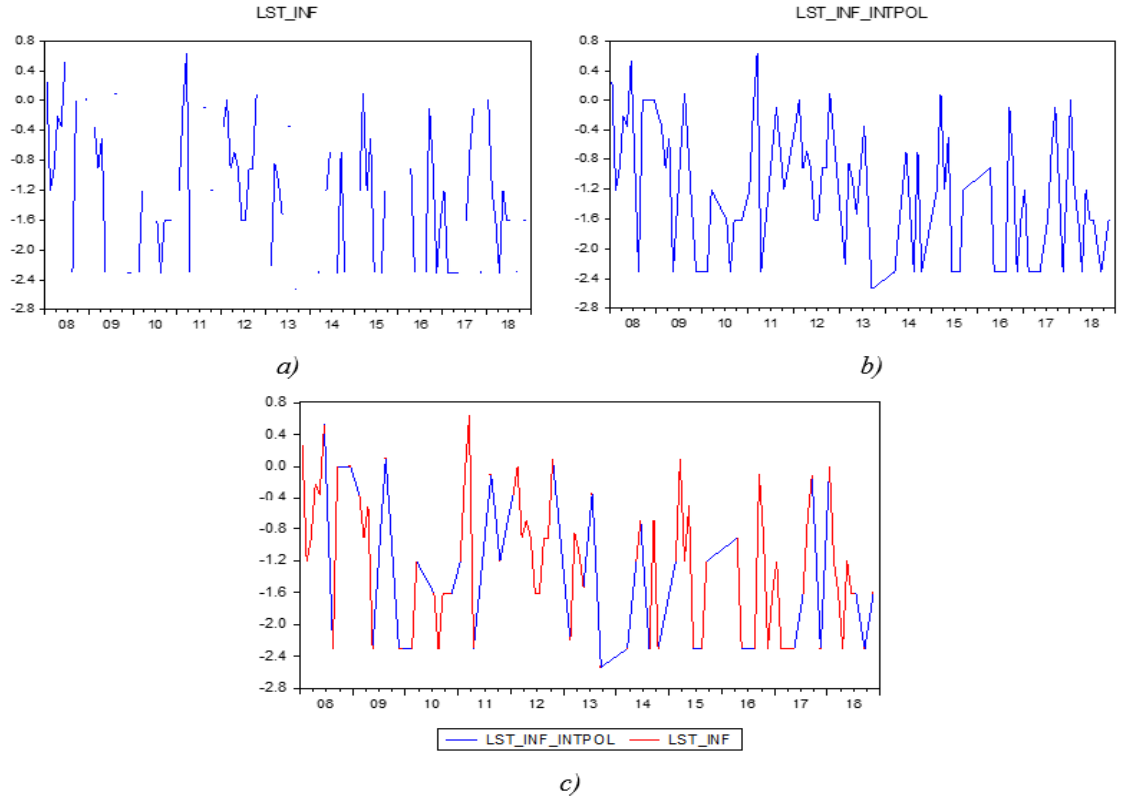

Grafik 7*: a) Logaritmovana serija podataka (stopa inflacije); b) Interpolirana logaritmovana serija podataka (stopa inflacije); c) Zajednički prikaz serija pod a) i b)*

Sada se pristupa formiranju modela u kome je zavisna varijabla interpolisana logaritmovana serija stope inflacije (označena kao ***lst_inf_intpol***), dok će nezavisna varijabla biti logaritmovana serija stope nezaposlenosti (označena kao ***lst_n***). Važno je napomenuti da su obje serije stacionarne[73]. Specifikacija jednačine je sljedeća: $\boldsymbol{lst_inf_inpol = \beta_0 + \beta_1 * lst_n + \varepsilon_t}$. Ocjena ovog modela je prikazana u ***Tabeli 10.***

Tabela 10*: Ocjena modela* $lst_inf_inpol = \beta_0 + \beta_1 * lst_n + \varepsilon_t$

Dependent Variable: LST_INF_INTPOL
Method: Least Squares
Sample (adjusted): 2008M01 2018M11
Included observations: 131 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-3.789531	0.921250	-4.113466	0.0001
LST_N	-1.391455	0.512662	-2.714179	0.0076

R-squared	0.054022	Mean dependent var	-1.296010
Adjusted R-squared	0.046689	S.D. dependent var	0.802704
S.E. of regression	0.783741	Akaike info criterion	2.365674
Sum squared resid	79.23827	Schwarz criterion	2.409570
Log likelihood	-152.9516	Hannan-Quinn criter.	2.383510
F-statistic	7.366768	Durbin-Watson stat	1.037976
Prob(F-statistic)	0.007553		

Iz ocjene modela se može vidjeti da je pripadajuća vjerovatnoća uz nezavisnu varijablu manja od 5%, što znači da se odbacuje nulta hipoteza i zaključuje da stopa nezaposlenosti ima statistički značajan uticaj na stopu inflacije. Model je statistički značajan, što se može zaključiti na osnovu pripadajuće vjerovatnoće za F-statistiku, koja je manja od 5% i iznosi 0,7%. Takođe, ako se stopa nezaposlenosti poveća za jedan procenat, stopa inflacije će se u prosjeku smanjiti za 1.39%, što znači da postoji inverzan odnos između stope inflacije i stope nezaposlenosti, kao i u originalnom modelu Filipsove krive. Međutim, vrijednost koeficijenta determinacije upućuje na to da je jako mali procenat varijabilnosti stope inflacije objašnjen stopom nezaposlenosti (svega 5%) pa model nije dobar za predviđanje kretanja stope inflacije.Vrijednost *Durbin-Watson* statistike, iznosi 1.037976, što nagovještava da je u modelu moguće postojanje pozitivne autokorelacije.

Kretanje stope inflacije i stope nezaposlenosti umnogome zavisi od ponašanja ekonomskih subjekata (donosioca makroekonomskih odluka ali i domaćinstava). Tokom vremena dolazi do promjena ne samo u političkom okruženju (koje je za naše prilike možda i najuticajnije), već uzročno-posljedično dolazi do promjena i u institucionalnom okruženju (izglasavanje zakona i njihova implementacija). Uticaj takvih kvantitativno nemjerljivih faktora na kretanje zavisne

[73] U Dodatku se nalazi prošireni *Dickey-Fuller*-ov test za testiranje stacionarnosti logaritmovane serije podataka stopa nezaposlenosti, i logaritmovane i interpolisane serije podataka stopa inflacije. Obje serije su stacionarne što nam omogućava njihovu upotrebu u konstruisanju modela.

promjenljive modelira se uključivanjem novih objašnjavajućih promjenljivih koje se nazivaju vještačke varijable.

S obzirom na to da je za period koji analiziramo (od 2008. do 2018. godine) došlo do određenih promjena u ekonomiji, faktori koji su izazvali te promjene mogu da utiču na stopu nezaposlenosti, pa na taj način i na stopu inflacije, samim tim je neophodno uključiti te varijable u model i ocijeniti da li zaista imaju uticaj na valjanost modela i povećanje vrijednosti koeficijenta determinacije. U model će biti uključene dvije vještačke varijable, $\boldsymbol{V_1}$ i $\boldsymbol{V_2}$.

$\boldsymbol{V_1}$ predstavlja vještačku varijablu kojom se obuhvata uticaj svjetske ekonomske krize na stopu inflacije za period od januara 2008. do jula 2009. godine, pa za opservacije na ovom dijelu uzorka vještačka vrijabla uzima vrijednost 1, dok za ostali posmatrani period ima vrijednost 0.

$\boldsymbol{V_2}$ je vještačka varijabla koja predstavlja period od uvođenja naknada za majke sa troje ili više djece do njegovog ukidanja i to je period od januara 2016. do jula 2017. godine. Prema izmijenjenom ***Zakonu o dopunama zakona o socijalnoj i dječjoj zaštiti, član 54a i 54b***[74] (*"Službeni list CG", br. 27/13 i 01/15*) važilo je sljedeće: *„Zaposlene majke sa troje ili više djece, koje imaju 25 ili 15 godina radnog staža, primaće doživotnu mjesečnu naknadu u iznosu od 70 odsto prosječne neto zarade u Crnoj Gori, ostvarene u godini koja prethodi onoj kada je ostvareno to pravo. Žena koja rodi troje i više djece, a na evidenciji Zavoda za zapošljavanje je najmanje 15 godina, imaće pravo, ukoliko to želi, na doživotnu mjesečnu naknadu u visini od 40 odsto prosječne neto zarade u Crnoj Gori. To pravo se ne može koristiti za vrijeme trajanja radnog odnosa i isključuje mogućnost istovremenog korišćenja penzije."*[75] Prema ovom Zakonu, prihvatanjem naknade, žene koje ispunjavaju uslove, napuštaju posao (ukoliko su radile), ne dobijaju penziju, niti imaju tu mogućnost, pa se broj nezaposlenih povećao. Ono što dodatno opravdava uvođenje ove vještačke varijable, u želji da se procijeni njen uticaj na model, jeste i činjenica da je na ***Grafiku 4.*** i ***6.*** primjetan rast stope nezaposlenosti upravo u periodu u kojem je V_2 uvedena. Za opservacije u periodu od januara 2016. do jula 2017. godine vještačka varijabla ima vrijednost 1, dok za ostali posmatrani period ima vrijednost 0.

Novi model će biti specifikovan na sljedeći način:

$$lst_inf_intpol = \beta_0 + \beta_1 * lst_n + \beta_2 * V_1 + \beta_3 * V_2 + \varepsilon_t.$$

[74] Zakon je izglasan na petoj sjednici prvog (redovnog) proljećnjeg zasijedanja, 15. jula 2015., a primjenjivao se od januara 2016. do jula 2017. godine.

[75] *Zakonom o izmjenama i dopunama Zakona o socijalnoj i dječjoj zaštiti ("Službeni list Crne Gore", br. 042/17 od 30.06.2017),* član 54a i 54b su izbrisani iz Zakona 30. juna 2017. godine, ali je ipak *Zakonom o obeštećenju bivših korisnica naknada po osnovu rođenja troje ili više djece* (*"Sl.list CG", broj 145/21*) omogućeno da, podnošenjem zahtjeva za obeštećenje od 8. januara do 9. marta 2022. godine, ostvare svoja prava.

U ***Tabeli 11.*** su prikazani rezultati, na osnovu kojih se dolazi do zaključka da varijable *lst_n* i V_2 nijesu statistički značajne, da je koeficijent objašnjenosti svega 14.1838%, ali da je na osnovu F-statistike model značajan.

***Tabela 11**: Ocjena modela lst_inf_intpol =* $\beta_0 + \beta_1 * lst_n + \beta_2 * V_1 + \beta_3 * V_2 + \varepsilon_t$

Dependent Variable: LST_INF_INTPOL
Method: Least Squares
Sample (adjusted): 2008M01 2018M11
Included observations: 131 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-1.940372	1.154506	-1.680694	0.0953
LST_N	-0.325587	0.637982	-0.510339	0.6107
V1	0.714024	0.205158	3.480354	0.0007
V2	-0.270791	0.233800	-1.158219	0.2489

R-squared	0.141838	Mean dependent var	-1.296010
Adjusted R-squared	0.121567	S.D. dependent var	0.802704
S.E. of regression	0.752332	Akaike info criterion	2.298781
Sum squared resid	71.88247	Schwarz criterion	2.386573
Log likelihood	-146.5702	Hannan-Quinn criter.	2.334455
F-statistic	6.996913	Durbin-Watson stat	1.166682
Prob(F-statistic)	0.000215		

Za procjenu značaja promjenljivih u modelu upotrijebljen je *Wald*-ov test. Rezultati ovog testa će omogućiti da se dođe do zaključka da li je statistički opravdano uvođenje ili odbacivanje promjenljivih iz modela i da se utvrdi da li model sadrži samo korisne promjenjljive. *Wald*-ovim testom (***Tabela 12***) će biti provjereno da li je konstanta (β_0) značajna za model (u *Tabeli 12*, konstanta β_0 je označena sa C(1)).

***Tabela 12**: Wald-ov test*

Wald Test:

Test Statistic	Value	df	Probability
t-statistic	-0.510339	127	0.6107
F-statistic	0.260446	(1, 127)	0.6107
Chi-square	0.260446	1	0.6098

Null Hypothesis: C(1)=0
Null Hypothesis Summary:

Normalized Restriction (= 0)	Value	Std. Err.
C(1)	-0.325587	0.637982

Na osnovu rezultata *Wald*-ovog testa i pripadajuće vjerovatnoće za hi-statistiku (0.6098) i F-statistiku (0.6107), prihvata se nulta hipoteza da konstanta ima vrijednost nula, što znači da nije značajna za model. Izostavljanjem β_0 iz modela dobijaju se sljedeći rezultati (***Tabela 13***):

***Tabela 13**: Ocjena modela lst_inf_intpol = β_1*lst_n + β_2*V_1 + β_3*V_2 + ε_t*

Dependent Variable: LST_INF_INTPOL
Method: Least Squares
Sample (adjusted): 2008M01 2018M11
Included observations: 131 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LST_N	0.744266	0.042957	17.32585	0.0000
V1	0.820161	0.196584	4.172073	0.0001
V2	-0.499774	0.191350	-2.611830	0.0101

R-squared	0.122751	Mean dependent var	-1.296010
Adjusted R-squared	0.109044	S.D. dependent var	0.802704
S.E. of regression	0.757676	Akaike info criterion	2.305512
Sum squared resid	73.48128	Schwarz criterion	2.371356
Log likelihood	-148.0110	Hannan-Quinn criter.	2.332267
Durbin-Watson stat	1.152161		

U modelu bez konstante sve varijable su statistički značajne ali je modelom objašnjeno samo 12.2751% varijacija stope inflacije, dok preostali procenat varijacija (97,63%) nije objašnjen modelom i pripisuje se faktorima čije je dejstvo uključeno u grešku modela. *DW* statistika iznosi 1.152, što sugeriše da je moguće da u modelu postoji pozitivna autokorelacija.

3.3.1. Ramsey Reset Test

Ramsey Reset Test je opšti test specifikacije za model linearne regresije koji služi za testiranje grešaka u specifikaciji, preciznije testira da li nelinearne kombinacije analiziranih varijabli pomažu u formiranju boljeg modela. Ovim testom se procjenjuje da li je model dobro specificiran. Polazna hipoteza *Ramsey Reset testa* tvrdi da u modelu ne postoje greške specifikacije.

U razmatranje su uzeti sljedeći modeli:
***Model 1**: lst_inf_intpol = β_0 + β_1*lst_n + ε_t (ocjena u **Tabeli 10**)*

***Model 2a**: lst_inf_intpol = β_1*lst_n + β_2*V_1 + β_3*V_2 + ε_t (ocjena u **Tabeli 13**)*

Na osnovu p vrijednosti koja iznosi 22,91% dolazi se do zaključka da u ***Modelu 1*** ne postoje greške specifikacije (***Tabela 14)***.

Tabela 14*: Ramsey Reset Test za ocijenjeni* ***Model 1****:*
*lst_inf_intpol = -3.789531 - 1.391455*lst_n*

Ramsey RESET Test
Specification: LST_INF_INTPOL C LST_N
Omitted Variables: Squares of fitted values

	Value	df	Probability
t-statistic	1.208399	128	0.2291
F-statistic	1.460229	(1, 128)	0.2291
Likelihood ratio	1.485993	1	0.2228

F-test summary:

	Sum of Sq.	df	Mean Squares
Test SSR	0.893757	1	0.893757
Restricted SSR	79.23827	129	0.614250
Unrestricted SSR	78.34452	128	0.612067

LR test summary:

	Value	df
Restricted LogL	-152.9516	129
Unrestricted LogL	-152.2086	128

Unrestricted Test Equation:
Dependent Variable: LST_INF_INTPOL
Method: Least Squares
Sample: 2008M01 2018M11
Included observations: 131

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-21.18823	14.42748	-1.468603	0.1444
LST_N	-9.139713	6.432390	-1.420889	0.1578
FITTED^2	2.049744	1.696247	1.208399	0.2291

R-squared	0.064692	Mean dependent var	-1.296010
Adjusted R-squared	0.050078	S.D. dependent var	0.802704
S.E. of regression	0.782347	Akaike info criterion	2.369597
Sum squared resid	78.34452	Schwarz criterion	2.435441
Log likelihood	-152.2086	Hannan-Quinn criter.	2.396353
F-statistic	4.426639	Durbin-Watson stat	1.054226
Prob(F-statistic)	0.013839		

U ***Modelu 2a***, *Ramsey Reset Test*-om, na osnovu vjerovatnoće 3,35%, potvrđuje se postojanje greške specifikacije. ***(Tabela 15)***

***Tabela 15**: Ramsey Reset Test za ocijenjeni **Model 2a**:*
*lst_inf_intpol=0.744266*lst_n+0.820161*V_1-0.499774*V_2*

Ramsey RESET Test
Specification: LST_INF_INTPOL LST_N V1 V2
Omitted Variables: Squares of fitted values

	Value	df	Probability
t-statistic	2.149168	127	0.0335
F-statistic	4.618923	(1, 127)	0.0335
Likelihood ratio	4.679807	1	0.0305

F-test summary:

	Sum of Sq.	df	Mean Squares
Test SSR	2.578690	1	2.578690
Restricted SSR	73.48128	128	0.574073
Unrestricted SSR	70.90259	127	0.558288

LR test summary:

	Value	df
Restricted LogL	-148.0110	128
Unrestricted LogL	-145.6711	127

Unrestricted Test Equation:
Dependent Variable: LST_INF_INTPOL
Method: Least Squares
Sample: 2008M01 2018M11
Included observations: 131

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LST_N	2.131144	0.646698	3.295423	0.0013
V1	2.969592	1.018738	2.914972	0.0042
V2	-2.216353	0.820706	-2.700544	0.0079
FITTED^2	1.375440	0.639987	2.149168	0.0335

R-squared	0.153536	Mean dependent var	-1.296010
Adjusted R-squared	0.133541	S.D. dependent var	0.802704
S.E. of regression	0.747187	Akaike info criterion	2.285055
Sum squared resid	70.90259	Schwarz criterion	2.372848
Log likelihood	-145.6711	Hannan-Quinn criter.	2.320729
Durbin-Watson stat	1.174513		

Kod svih modela koji su do sada testirani, na osnovu *DW* statistike, primjećuje se da postoji mogućnost postojanja pozitivne autokorelacije. Iz tog razloga, formalnim testom će biti ispitano njeno postojanje. Ukoliko se utvrdi postojanje autokorelacije pristupiće se njenom otklanjanju.

S obzirom na to da ocijenjeni ***Model 2a*** sadrži vještačke varijable koje su uz to i statistički značajne a i stepen objašnjenosti modela je veći u odnosu na ocijenjeni ***Model 1***, testiraće se da li moguće postojanje autokorelacije izaziva greške specifikacije ***Modela 2a***. Postojanje autokorelacije će biti testirano *Breusch-Godfrey Test*-om.

***Tabela 16**: Breusch-Godfrey Test za ocijenjeni **Model 2a**:*
*lst_inf_intpol=0.744266*lst_n+0.820161*V_1-0.499774*V_2*

Breusch-Godfrey Serial Correlation LM Test:

F-statistic	15.46124	Prob. F(2,126)	0.0000
Obs*R-squared	25.81431	Prob. Chi-Square(2)	0.0000

U ***Tabeli 16*** na osnovu vjerovatnoće 0%, dolazi se do zaključka da u modelu postoji problem autokorelacije grešaka, što znači da je narušena jedna od pretpostavki klasičnog linearnog regresionog modela po kojoj slučajne greške nijesu korelisane. Iz tog razloga se pristupa otklanjanju autokorelacije. U cilju otklanjanja autokorelacije u model se dodaje zavisna varijabla (logaritmovana i interpolisana serija stopa inflacije) sa docnjom prvog reda. Ocjena ***Modela 2*** nakon otklanjanja autokorelacije prikazana je u ***Tabeli 17***.

***Tabela 17**: Ocjena **Modela 2a** nakon otklanjanja autokorelacije*

Dependent Variable: LST_INF_INTPOL
Method: Least Squares
Sample (adjusted): 2008M02 2018M11
Included observations: 130 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LST_N	0.416912	0.071180	5.857179	0.0000
V1	0.386159	0.194870	1.981629	0.0497
V2	-0.305901	0.176156	-1.736541	0.0849
LST_INF_INTPOL(-1)	0.437059	0.079795	5.477248	0.0000

R-squared	0.276707	Mean dependent var	-1.307997
Adjusted R-squared	0.259486	S.D. dependent var	0.793950
S.E. of regression	0.683219	Akaike info criterion	2.106284
Sum squared resid	58.81536	Schwarz criterion	2.194516
Log likelihood	-132.9085	Hannan-Quinn criter.	2.142136
Durbin-Watson stat	1.858952		

U ocijenjenom ***Modelu 2a*** nakon otklanjanja autokorelacije, svi parametri su statistički značajni. Koeficijent korelacije modela je povećan i iznosi 27.6707%. Uz pomoć *Ramsey Reset Test*-a biće utvrđeno da li je, nakon otklanjanja autokorelacije, model dobro specificiran.

***Tabela 18**: Ramsey Reset Test nakon otklanjanja autokorelacije*

Ramsey RESET Test
Specification: LST_INF_INTPOL LST_N V1 V2 LST_INF_INTPOL(-1)
Omitted Variables: Squares of fitted values

	Value	df	Probability
t-statistic	1.150062	125	**0.2523**
F-statistic	1.322643	(1, 125)	0.2523
Likelihood ratio	1.368323	1	0.2421

F-test summary:

	Sum of Sq.	df	Mean Squares
Test SSR	0.631303	1	0.631303
Restricted SSR	60.29431	126	0.478526
Unrestricted SSR	59.66301	125	0.477304

LR test summary:

	Value	df
Restricted LogL	-134.5227	126
Unrestricted LogL	-133.8386	125

Unrestricted Test Equation:
Dependent Variable: LST_INF_INTPOL
Method: Least Squares
Sample: 2008M02 2018M11
Included observations: 130

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LST_N	0.330280	0.112108	2.946086	0.0038
V1	0.091972	0.248750	0.369735	0.7122
V2	0.189736	0.299529	0.633446	0.5276
LST_INF_INTPOL(-1)	0.051758	0.364826	0.141871	0.8874
FITTED^2	-0.357665	0.310996	-1.150062	0.2523

R-squared	0.266283	Mean dependent var	-1.307997
Adjusted R-squared	0.242804	S.D. dependent var	0.793950
S.E. of regression	0.690872	Akaike info criterion	2.135978
Sum squared resid	59.66301	Schwarz criterion	2.246268
Log likelihood	-133.8386	Hannan-Quinn criter.	2.180792
Durbin-Watson stat	1.879992		

Na osnovu rezultata t statistike (1,150062) i vjerovatnoće od 25,23%, iz ***Tabele 18*** potvrđeno je da je model dobro specificiran. Osjetljivost specifikacije u uzorku se može ispitati na osnovu rekurzivnih reziduala (***Grafik 8***). Na x-osi je predstavljena veličina uzorka, dok se rekurzivni reziduali ucrtavaju oko nulte linije sa granicom od plus i minus dvije standardne devijacije. Reziduali izvan ovih granica sugerišu nestabilnost ocijenjenog modela u datoj opservaciji. Dakle, model je stabilan jer plava linija ne dotiče niti presijeca crvenu, osim u septembru 2016. godine (***Grafik 8***).

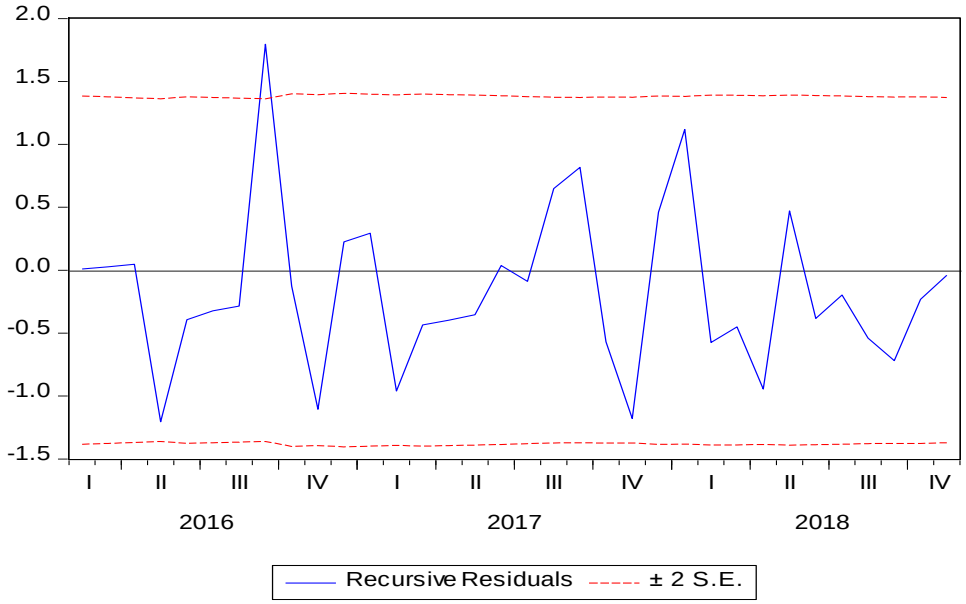

***Grafik 8**: Testiranje stabilnosti ocijenjenog **Modela 2a** (nakon otklonjene autokorelacije) na osnovu reziduala*

Međutim, da bi sa sigurnošću bio procijenjen uticaj eksternog šoka na poboljšanje modela, uvodi se vještačka varijabla za septembar 2016. godine (V_{2016m9}). V_{2016m9} uzima vrijednost 1 za septembar 2016, i vrijednost 0 za ostali vremenski period.

***Tabela 19**: Ocjena modela: $lst_inf_intpol = \beta_1 * lst_n + \beta_2 * V_1 + \beta_3 * V_2 + \beta_4 * lst_inf_intpol(-1) + \beta_5 * V_{2016m9} + \varepsilon_t$*

Dependent Variable: LST_INF_INTPOL
Method: Least Squares
Sample (adjusted): 2008M02 2018M11
Included observations: 130 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LST_N	0.379806	0.066130	5.743310	0.0000
V1	0.384280	0.246455	1.559228	0.1215
V2	-0.406531	0.171773	-2.366674	0.0195
LST_INF_INTPOL(-1)	0.468701	0.077236	6.068434	0.0000
V2016M9	2.009955	0.687686	2.922780	0.0041

R-squared	0.314833	Mean dependent var	-1.307997
Adjusted R-squared	0.292908	S.D. dependent var	0.793950
S.E. of regression	0.667623	Akaike info criterion	2.067517
Sum squared resid	55.71508	Schwarz criterion	2.177806
Log likelihood	-129.3886	Hannan-Quinn criter.	2.112331
Durbin-Watson stat	1.899266		

Uvođenjem vještačke varijable, V_{2016m9}, dobija se model sa većim koeficijentom determinacije (31,48%). Objašnjenje uticaja V_{2016m9} se može pripisati održavanju parlamentarnih izbora u septembru 2016. godine. Takođe, rezultati ocjene modela iz ***Tabele 19.*** upućuju na to da sve nezavisne varijable imaju statistički značajan uticaj na zavisnu varijablu (logaritmovanu i

interpolisanu seriju stopa inflacije), osim varijable V_1, pa će u narednom poglavlju *Redundant Variable* testom biti ispitana relevantnost svih promjenljivih u ocijenjenom modelu.

3.3.2. Redundant Variable Test

U ***Tabeli 20***, pomoću *Redundant Variable Test*-a (test suvišnih varijabli), ispitano je da li je varijabla stopa nezaposlenosti značajna za model. Polazna hipoteza ovog testa tvrdi da stopa nezaposlenosti nije relevantna za model. Uz vjerovatnoću 0% odbacuje se polazna hipoteza i zaključuje se da je stopa nezaposlenosti relevantna za model.

***Tabela 20**: Redundant Variable test za varijablu lst_n*

Redundant Variables Test
Specification: LST_INF_INTPOL LST_N V1 V2 LST_INF_INTPOL(-1) V2016M9
Redundant Variables: LST_N

	Value	df	Probability
t-statistic	5.743310	125	0.0000
F-statistic	32.98561	(1, 125)	0.0000
Likelihood ratio	30.44473	1	0.0000

F-test summary:

	Sum of Sq.	df	Mean Squares
Test SSR	14.70237	1	14.70237
Restricted SSR	70.41745	126	0.558869
Unrestricted SSR	55.71508	125	0.445721
Unrestricted SSR	55.71508	125	0.445721

LR test summary:

	Value	df
Restricted LogL	-144.6109	126
Unrestricted LogL	-129.3886	125

Restricted Test Equation:
Dependent Variable: LST_INF_INTPOL
Method: Least Squares
Sample: 2008M02 2018M11
Included observations: 130

Variable	Coefficient	Std. Error	t-Statistic	Prob.
V1	-0.217781	0.249762	-0.871957	0.3849
V2	-0.412175	0.192341	-2.142942	0.0340
LST_INF_INTPOL(-1)	0.839298	0.047530	17.65841	0.0000
V2016M9	2.239370	0.768740	2.913037	0.0042

R-squared	0.134028	Mean dependent var	-1.307997
Adjusted R-squared	0.113410	S.D. dependent var	0.793950
S.E. of regression	0.747575	Akaike info criterion	2.286322
Sum squared resid	70.41745	Schwarz criterion	2.374554
Log likelihood	-144.6109	Hannan-Quinn criter.	2.322174
Durbin-Watson stat	2.120610		

Redundant Variable testom će biti analizirana opravdanosti uvođenja ostalih varijabli u model. Iz ***Tabele 21***, na osnovu vjerovatnoća za nezavisne varijable: V_2, *lst_inf_intpol(-1)*, V_{2016m9} potvrđuje se njihova relevantnost za model. Međutim, u slučaju varijable V_1 p vrijednost je 12,15% (što je veće od željenog nivoa značajnosti od 10%). Takav rezultat sugeriše da V_1 nije relevantna za model. Takođe, rezultati ocijenjenog modela iz ***Tabele 19.*** upućuju da V_1 nema statistički značajan uticaj na zavisnu varijablu, što opravdava činjenicu da se može ukloniti iz specifikacije modela u cilju poboljšanja rezultata.

Tabela 21*: Redundant Variable Test za varijable:* V_1, V_2, V_{2016m9} *i lst_inf_intpol(-1)*

Redundant Variables Test
Specification: LST_INF_INTPOL LST_N V2 V3 LST_INF_INTPOL(-1) V2016M9
Redundant Variables: **V1**

	Value	df	Probability
t-statistic	1.559228	125	**0.1215**
F-statistic	2.431193	(1, 125)	0.1215
Likelihood ratio	2.504167	1	0.1135

Redundant Variables: **V2**

	Value	df	Probability
t-statistic	2.366674	125	0.0195
F-statistic	5.601145	(1, 125)	0.0195
Likelihood ratio	5.698452	1	0.0170

Redundant Variables: **LST_INF_INTPOL(-1)**

	Value	df	Probability
t-statistic	6.068434	125	0.0000
F-statistic	36.82589	(1, 125)	0.0000
Likelihood ratio	33.56694	1	0.0000

Redundant Variables: **V2016M9**

	Value	df	Probability
t-statistic	2.922780	125	0.0041
F-statistic	8.542643	(1, 125)	0.0041
Likelihood ratio	8.593925	1	0.0034

Nakon spovedenih testova, specifikacija konačnog modela je sljedeća: $lst_inf_intpol = \beta_1 * lst_n + \beta_2 * V_2 + \beta_3 * lst_inf_intpol(-1) + \beta_4 * V_{2016m9} + \varepsilon_t$, dok je ocjena modela data u ***Tabeli 22***. Ovaj model će u nastavku teksta biti označen kao ***Model 2***.

***Tabela 22**: Ocjena **Modela 2**: lst_inf_intpol = β_1*lst_n + β_2*V_2 + β_3*lst_inf_int(-1) + β_4*V_{2016m9}+ ε_t*

Dependent Variable: LST_INF_INTPOL
Method: Least Squares
Sample (adjusted): 2008M02 2018M11
Included observations: 130 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LST_N	0.335948	0.060189	5.581565	0.0000
V2	-0.413743	0.172683	-2.395969	0.0180
LST_INF_INTPOL(-1)	0.507452	0.073542	6.900125	0.0000
V2016M9	2.033696	0.691411	2.941371	0.0039

R-squared	0.301507	Mean dependent var	-1.307997
Adjusted R-squared	0.284876	S.D. dependent var	0.793950
S.E. of regression	0.671404	Akaike info criterion	2.071395
Sum squared resid	56.79872	Schwarz criterion	2.159627
Log likelihood	-130.6407	Hannan-Quinn criter.	2.107246
Durbin-Watson stat	1.892277		

U odnosu na sve ispitane modele, izabran je ocijenjeni ***Model 2*** iz ***Tabele 22***: *lst_inf_intpol = 0,33*lst_n - 0,41*V_2 + 0,51*lst_inf_intpol(-1) + 2,03*V_{2016m9}*. U nastavku će biti sprovedeno ispitivanje normalnosti slučajne greške izabranog modela i *Granger*-ov test kauzalnosti.[76]

3.3.3. Jarque-Bera Test

Slučajna greška igra bitnu ulogu u specifikaciji modela, pa je važno da posjeduje normalnu raspodjelu, što je ujedno i jedna od pretpostavki klasičnog linearnog regresionog modela. Zato se, kao naredni korak, podrazumijeva testiranje normalnosti raspodjele slučajne greške. Na ***Grafiku 9*** izračunata vjerovatnoća je 97,53%, pa dolazimo do zaključka da serija reziduala modela ima normalan raspored.

[76] Za ocijenjeni model: *lst_inf_intpol = β_1*lst_n + β_2*V_1 + β_3*V_2 + β_4*lst_inf_intpol(-1) + β_5*V_{2016m9} (Tabela 19.),* u dodatku su dati rezultati testova autokorelacije, heteroskedastičnosti, multikolinearnosti i normalnosti raspodjele reziduala. Rezultati testova su kao i kod ocijenjenog modela iz *Tabele 22*.

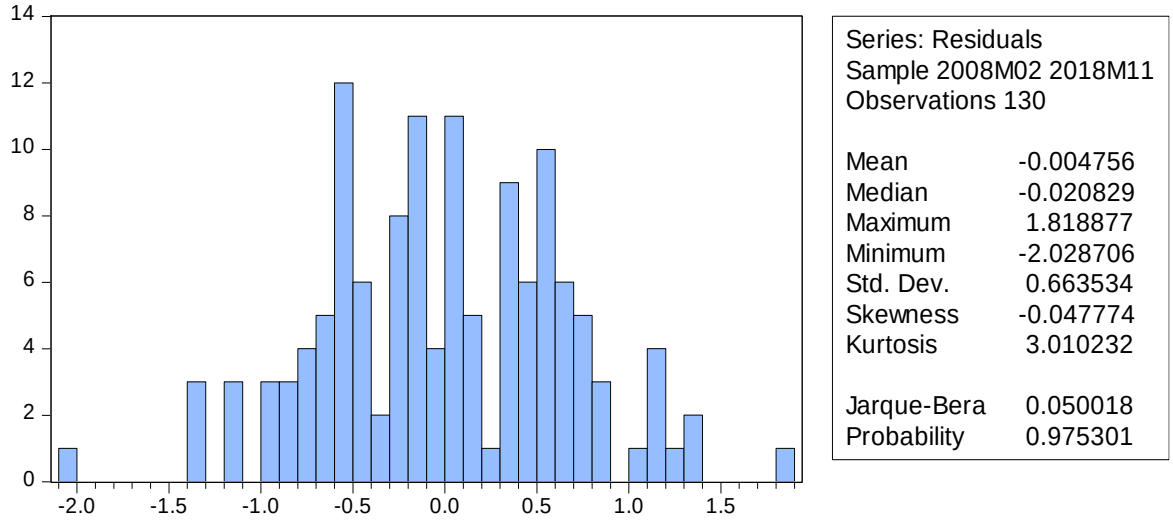

***Grafik 9**: Histogram reziduala ocijenjenog **Modela 2**: lst_inf_intpol = 0,33*lst_n - 0,41*V_2 + 0,51*lst_inf_int(-1) + 2,03*V_{2016m9}*

3.3.4. Granger Causality Test

Primjenom *Granger*-ovog testa kauzalnosti ispituje se da li podaci, dobijeni na osnovu vrijednosti jedne promjenljive iz prethodnog perioda, omogućavaju preciznije predviđanje sadašnje vrijednosti druge varijable. *Granger*-ova kauzalnost ukazuje da postoji korelacija između prošlih vrijednosti jedne promenljive i sadašnje vrijednosti druge. Nulta hipoteza ovog testa je da između varijabli ne postoji kauzalnost. Za testiranje hipoteze posmatra se vrijednost F-statistike, a zaključak se donosi na osnovu pripadajuće vjerovatnoće. Ako je izračunata vjerovatnoća manja od željenog nivoa značajnosti onda se odbacuje nulta hipoteza, odnosno dolazi se do zaključka da varijable utiču jedna na drugu.

***Tabela 23**: Granger-ov test kauzalnosti*

Pairwise Granger Causality Tests
Sample: 2008M01 2018M12
Lags: 2

Null Hypothesis:	Obs	F-Statistic	Prob.
LST_N does not Granger Cause LST_INF_INTPOL	129	1.23631	0.2940
LST_INF_INTPOL does not Granger Cause LST_N		2.62401	0.0765
LST_INF_INTPOL(-1) does not Granger Cause LST_N	129	2.38339	0.0965
LST_N does not Granger Cause LST_INF_INTPOL(-1)		1.58840	0.2084

Lags: 3

Null Hypothesis:	Obs	F-Statistic	Prob.
LST_N does not Granger Cause LST_INF_INTPOL	128	0.71268	0.5463
LST_INF_INTPOL does not Granger Cause LST_N		1.86037	0.1399
LST_INF_INTPOL(-1) does not Granger Cause LST_N	128	1.90111	0.1330
LST_N does not Granger Cause LST_INF_INTPOL(-1)		0.97505	0.4069

Ho: LST_ N ne utiče na LST_INF_INTPOL, dok bi alternativna hipoteza glasila H1: LST_N utiče na LST_INF_INTPOL. Testom se dolazi do zaključka da, uz nivo značajnosti od 10% i vjerovatnoću 29,40% ne postoji uticaj stope nezaposlenosti na stopu inflacije. Međutim, stopa inflacije iz prehodnog perioda (perioda od 2 mjeseca, 2 laga) utiče na stopu nezaposlenosti. Zaključak je da postoji jednosmjerna uzročnost od stope inflacije prema stopi nezaposlenosti, suprotno ne važi. Na nivou od 3 laga ne postoji međusobni uticaj varijabli.

3.4. Ocjena i vrednovanje modela Filipsove krive u Crnoj Gori

Iz dosadašnjeg istraživanja, prilagođavanjem serija u cilju formiranja valjanog modela, izabran je model u kojem su sve varijable statistički značajne, a koji istovremeno ima i najveći koeficijent determinacije. Radi vrednovanja ocijenjenog modela u narednim poglavljima će biti sprovedeni ekonometrijski testovi. Sprovođenjem ekonometrijskih testova provjerava se da li su ispunjene pretpostavke klasičnog linearnog regresionog modela, kroz testiranje postojanja autokorelacije, heteroskedastičnosti i multikolinearnosti.

3.4.1. Ispitivanje autokorelacije: Breusch-Godfrey Serial Correlation LM Test

Testiranje autokorelacije u modelu će biti sprovedeno *Breusch-Godfrey Serial Correlation LM* testom (***Tabela 24***). Rezultati testa ukazuju da je procenat greške koji se pravi, u slučaju odbacivanja nulte hipoteze, jednak 59,88%. Dakle, zaključak je da u modelu ne postoji problem autokorelacije grešaka.

***Tabela 24**: Testiranje autokorelacije: Breusch-Godfrey Test za **Model 2**:*
*lst_inf_intpol = 0,33*lst_n - 0,41*V_2 + 0,51*lst_inf_int(-1) + 2,03*V_{2016m9}*

Breusch-Godfrey Serial Correlation LM Test:

F-statistic	0.496271	Prob. F(2,124)	0.6100
Obs*R-squared	1.025627	Prob. Chi-Square(2)	0.5988

Test Equation:
Dependent Variable: RESID
Method: Least Squares
Sample: 2008M02 2018M11
Included observations: 130
Presample missing value lagged residuals set to zero.

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LST_N	0.045477	0.130465	0.348576	0.7280
V2	-0.037332	0.196164	-0.190312	0.8494
LST_INF_INTPOL(-1)	-0.068081	0.187532	-0.363037	0.7172
V2016M9	-0.031036	0.697701	-0.044483	0.9646
RESID(-1)	0.118533	0.202872	0.584276	0.5601
RESID(-2)	-0.032835	0.129866	-0.252834	0.8008

R-squared	0.007889	Mean dependent var	-0.004756
Adjusted R-squared	-0.032115	S.D. dependent var	0.663534
S.E. of regression	0.674104	Akaike info criterion	2.094192
Sum squared resid	56.34769	Schwarz criterion	2.226539
Log likelihood	-130.1225	Hannan-Quinn criter.	2.147969
Durbin-Watson stat	1.992324		

3.4.2. Ispitivanje heteroskedastičnosti: Glejser test

Postojanje heteroskedastičnosti u modelu će biti ispitano *Glejser*-ovim testom. Nulta hipoteza glasi (H_0): Slučajne greške imaju konstantnu varijansu (homoskedastične su), dok alternativna hipoteza glasi (H_1): Varijansa slučajne greške nije konstantna (greške su heteroskedastične). Na nivou značajnosti 5%, i na osnovu vrijednosti vjerovatnoće (***Tabela 25)*** koja iznosi 5,99%, zaključak je da važi nulta hipoteza kojom se tvrdi da u modelu ne postoji problem heteroskedastičnosti.

***Tabela 25**: Testiranje heteroskedastičnosti: Glejser-ov test za ocijenjeni Model 2:*
*lst_inf_intpol = 0,33*lst_n - 0,41*V_2 + 0,51*lst_inf_intpol(-1) + 2,03*V_{2016m9}*

Heteroskedasticity Test: Glejser

F-statistic	2.337560	Prob. F(4,125)	0.0589
Obs*R-squared	9.047481	Prob. Chi-Square(4)	0.0599
Scaled explained SS	8.479592	Prob. Chi-Square(4)	0.0755

Test Equation:
Dependent Variable: ARESID
Method: Least Squares
Sample: 2008M02 2018M11
Included observations: 130

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.651931	0.589446	1.106005	0.2708
LST_N	-0.012562	0.316391	-0.039703	0.9684
V2	-0.116738	0.120935	-0.965290	0.3363
LST_INF_INTPOL(-1)	0.094646	0.043591	2.171233	0.0318
V2016M9	-0.338084	0.397770	-0.849948	0.3970

R-squared	0.069596	Mean dependent var	0.532343
Adjusted R-squared	0.039823	S.D. dependent var	0.393337
S.E. of regression	0.385426	Akaike info criterion	0.968766
Sum squared resid	18.56913	Schwarz criterion	1.079056
Log likelihood	-57.96979	Hannan-Quinn criter.	1.013580
F-statistic	2.337560	Durbin-Watson stat	1.663034
Prob(F-statistic)	0.058926		

Postojanje heteroskedastičnosti se može ispitati i neformalnim (grafičkim) putem, odnosno dijagramom rasturanja reziduala (prikazano na ***Grafiku 10***). Sa grafika se jasno vidi da ne postoji zavisnost između varijansi slučajnih grešaka i nezavisnih promjenljivih za izabrani model, tj. slučajne greške su homoskedastične.

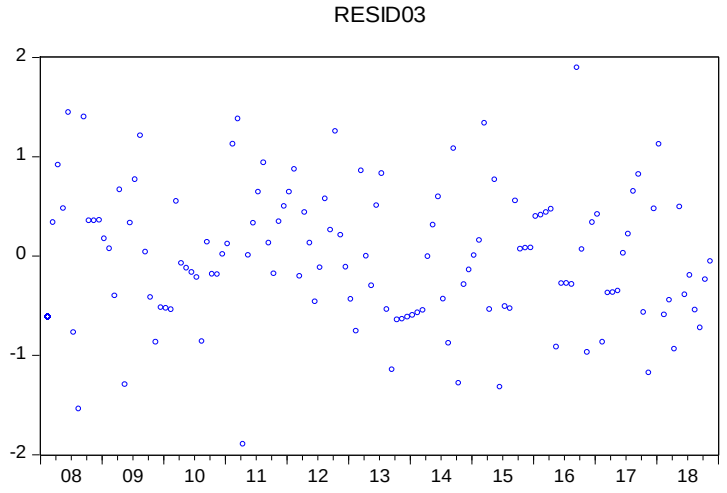

***Grafik 10**: Testiranje heteroskedastičnosti uz pomoć dijagrama rasturanja*

3.4.3. Multikolinearnost

S obzirom na to da finalni model sadrži više nezavisnih promjenljivih problem multikolinearnosti će biti prisutan, pa se kao važno pitanje ističe u kom stepenu je multikolinearnost izražena. Odgovor na ovo pitanje daje vrijednost faktora rasta varijanse (VIF). Prema podacima iz ***Tabele 26***, VIF se kreće u rasponu od 1,06 do 3,37. Dakle, multikolinearnost je umjerena.

Tabela 26*: Testiranje multikolinearnosti (za ocijenjeni* ***Model 3****)*

Variance Inflation Factors
Sample: 2008M01 2018M12
Included observations: 130

Variable	Coefficient Variance	Uncentered VIF
LST_N	0.003623	3.373222
V2	0.029819	1.256855
LST_INF_INTPOL(-1)	0.005408	3.613864
V2016M9	0.478049	1.060485

S obzrom na dosadašnje karakteristike izabranog i ocijenjeg modela, kao i na vrijednost koeficijenta determinacije nije poželjno vršiti bilo kakve prognoze, niti ga koristiti za svrhe kreiranja ekonomske politike.

Nakon prethodne analize, postoji mogućnost da se uzorak proširi do januara 2022. godine. U ***Tabeli 27.*** su predstavljeni rezultati Granger-ovog testa kauzalnosti.

Tabela 27: *Granger Causality Test (period 2008m1-2022m1)*

Pairwise Granger Causality Tests
Sample: 2008M01 2022M01
Lags: 2

Null Hypothesis:	Obs	F-Statistic	Prob.
LST_INF_INTPOL does not Granger Cause LST_N	167	4.82048	0.0093
LST_N does not Granger Cause LST_INF_INTPOL		0.59276	0.5540

Lags: 3

Null Hypothesis:	Obs	F-Statistic	Prob.
LST_INF_INTPOL does not Granger Cause LST_N	166	3.38323	0.0197
LST_N does not Granger Cause LST_INF_INTPOL		0.28007	0.8397

Lags: 4

Null Hypothesis:	Obs	F-Statistic	Prob.
LST_INF_INTPOL does not Granger Cause LST_N	165	2.96976	0.0213
LST_N does not Granger Cause LST_INF_INTPOL		0.58065	0.6771

Granger causality test ukazuje da, na nivou značajnosti 10%, stopa inflacije iz prethodnog perioda (period od 2, 3 i 4 mjeseca) utiče na stopu nezaposlenosti, ali obrnuto ne važi. Dakle, uzročnost između posmatranih varijabli je jednosmjerna.

U model je dodata je i vještačka varijabla V_3, za period od marta 2019. do januara 2022. godine. Opravdanost uvođenja treće vještačke varijable ogleda se kroz uticaj COVID pandemije na stopu nezaposlenost i stopu inflacije. Model je prikazan u ***Tabeli 28*** (u daljem tekstu model iz ***Tabele 28*** će biti obilježen kao ***Model 3a***).

***Tabela 28**: Ocjena **Modela 3a**: $lst_inf_intpol = \beta_1 * lst_n + \beta_2 * V_1 + \beta_3 * V_2 + \beta_4 * V_3 + \beta_5 * lst_inf_intpol(-1) + \beta_6 * V_{2016m9} + \varepsilon_t$*

Dependent Variable: LST_INF_INTPOL
Method: Least Squares
Sample (adjusted): 2008M02 2022M01
Included observations: 168 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LST_N	0.427248	0.064705	6.603048	0.0000
V1	0.424076	0.182157	2.328073	0.0211
V2	-0.395240	0.170201	-2.322199	0.0215
V3	-0.172799	0.130387	-1.325274	0.1869
LST_INF_INTPOL(-1)	0.428934	0.070443	6.089114	0.0000
V2016M9	1.985735	0.683801	2.903968	0.0042

R-squared	0.316714	Mean dependent var	-1.356508
Adjusted R-squared	0.295625	S.D. dependent var	0.791320
S.E. of regression	0.664132	Akaike info criterion	2.054388
Sum squared resid	71.45348	Schwarz criterion	2.165958
Log likelihood	-166.5686	Hannan-Quinn criter.	2.099669
Durbin-Watson stat	1.877990		

Ocjena ***Modela 3a*** iz ***Tabele 28*** je sljedeća: $lst_inf_intpol = 0{,}427248 * lst_n + 0{,}4240076 * V_1 - 0{,}395240 * V_2 - 0{,}172799 * V_3 + 0{,}428934 * lst_inf_intpol(-1) + 1{,}985735 * V_{2016m9}$. Koeficijent determinacije je 31,67%, sve varijable su statistički značajne osim vještačke varijable, V_3.

Na ***Grafiku 11.*** je prikazana osjetljivost specifikacije u uzorku koristeći rekurzivne reziduale. Reziduali izvan plus minus dvije standardne devijacije sugerišu nestabilnost ocijenjenog modela. Sa grafika se može vidjeti da nema odstupanja van 2 standardne devijacije, ali da plava linija presijeca crvenu u septembru 2020. i januaru 2022. godine. Iz tog razloga, a radi poboljšanja modela, biće uvedene vještačke varijable za te periode, V_{2020m9} i V_{2022m1}, respektivno.

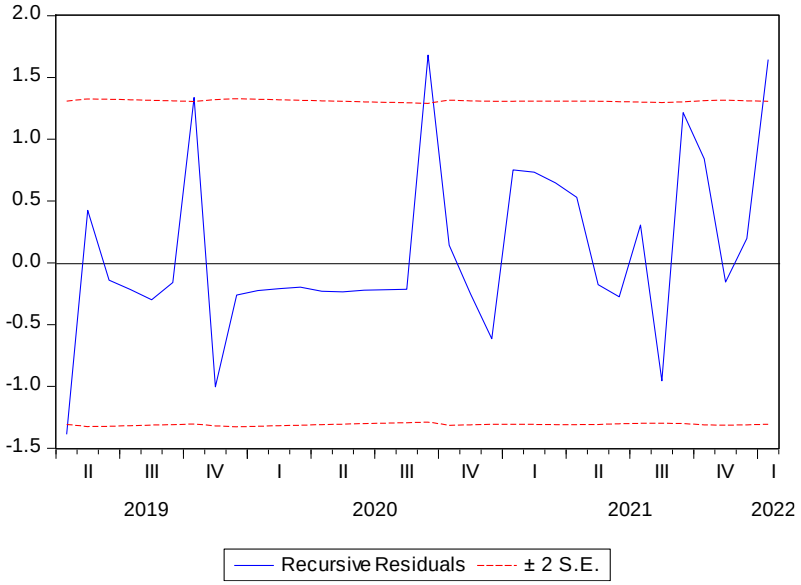

***Grafik 11**: Testiranje stabilnosti ocijenjenog **Modela 3a** na osnovu reziduala*

Nakon uvođenja vještačkih varijabli, u modelu dolazi do povećanja koeficijenta determinacije na 36,65%, što je i najveća vrijednost u, do sada, ispitivanim modelima. Za periode kada su uvedene vještačke varijable, septembar 2016. i 2020. godine, kao i januar 2022. godine dogodili su se eksterni šokovi (septembar 2016. i 2020.-parlamentarni izbori; januar 2022.-implementacija programa *"Evropa sad")* koji u određenoj mjeri mogu da utiču na valjanost modela, pa je sa tog stanovišta njihovo uvođenje opravdano.

***Tabela 29**: Ocjena **Modela 3a** nakon uvođenja **V_{2020m9} i V_{2022m1}**: $lst_inf_intpol = \beta_1 * lst_n + \beta_2 * V_1 + \beta_3 * V_2 + \beta_4 * V_3 + \beta_5 * lst_inf_intpol(-1) + \beta_6 * V_{2016m9} + \beta_7 * V_{2020m9} + \beta_8 * V_{2022m1} + \varepsilon_t$*

Dependent Variable: LST_I_IP
Method: Least Squares
Sample (adjusted): 2008M02 2022M01
Included observations: 168 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LST_N	0.421228	0.062899	6.696922	0.0000
V1	0.416786	0.176686	2.358908	0.0195
V2	-0.393305	0.165038	-2.383118	0.0183
V3	-0.265426	0.129143	-2.055290	0.0415
LST_INF_INTPOL(-1)	0.436056	0.068561	6.360140	0.0000
V2016M9	1.990221	0.662993	3.001873	0.0031
V2020M9	1.581412	0.655708	2.411764	0.0170
V2022M1	1.710968	0.653955	2.616338	0.0097

R-squared	0.365617	Mean dependent var	-1.356508
Adjusted R-squared	0.337862	S.D. dependent var	0.791320
S.E. of regression	0.643912	Akaike info criterion	2.003938
Sum squared resid	66.33957	Schwarz criterion	2.152698
Log likelihood	-160.3308	Hannan-Quinn criter.	2.064312
Durbin-Watson stat	1.916115		

U cilju pojednostavljenja, ocijenjeni ***Model 3a*** nakon otklanjanja autokorelacije: *lst_inf_intpol = 0,4212118*lst_n + 0,416786*V_1 - 0,393305)*V_2 - 0,265426)*V_3 + 0,436056*lst_inf_intpol(-1) + 1.990221*V_{2016m9} + 1.581412*V_{2020m9} + 1.710968*V_{2022m1}* će biti označen kao ***Model 3***. Rezultati Redundant Variable testa ukazuju da su sve varijable u modelu značajne i opravdano uvedene, dok reziduali imaju normalnu raspodjelu. Takođe, u ***Modelu 3*** ne postoji problem autokorelacije grešaka, niti problem heteroskedastičnosti. Vrijednost VIF-a se kreće od 1 do 5, što upućuje da ne postoji problem štetne multikolinearnosti.[77]

3.5. Finalna interpretacija rezultata

Istraživanje je sprovedeno na empirijskim podacima vremenskih serija stopa inflacije i stopa nezaposlenosti, koje su preuzete sa sajta CBCG. Na samom početku su utvrđene karakteristike vremenskih serija uz pomoć deskriptivne statistike. Testirana je normalnost raspodjele podataka i stacionarnost vremenskih serija. Originalne serije su stacionarne i nemaju normalan raspored. Specifikacijom željenog modela definisano je da stopa inflacije bude zavisna a stopa nezaposlenosti nezavisna varijabla. U tako ocijenjenom modelu parametri nijesu statistički značajni, a koeficijent korelacije iznosi 0,7378%. Modelom je ocijenjeno da ukoliko stopa inflacije poraste za jedan procenat, stopa nezaposlenosti će porasti za približno 1.02%, što je suprotno teorijskoj postavci. U narednom koraku je sprovedena transformacija originalnih serija njihovim logaritmovanjem. U modelu sa logaritmovanim serijama (***Model 1***) pokazalo se da su varijable statistički značajne, međutim, koeficijent determinacije je i dalje bio jako nizak, svega 5,4%. Ocjena ***Modela 1*** je sljedeća: *lst_inf_intpol = -3,78 - 1,39*lst_n*.[78]

Kako je u ispitivanom periodu došlo do određenih promjena u ekonomiji, koje su mogle uticati na nezaposlenost i inflaciju, bilo je neophodno uključiti ih u model i vidjeti kakav uticaj one ostvaruju. Za prvi analizirani period, od 2008. do 2018. godine, uključene su dvije vještačke varijable. V_1 predstavlja vještačku varijablu kojom se obuhvata uticaj svjetske ekonomske krize na stopu inflacije, za period od januara 2008. do jula 2009. godine, dok je V_2 vještačka varijabla koja predstavlja period od uvođenja naknada za majke sa troje ili više djece do njegovog ukidanja i to je period od januara 2016. do jula 2017. godine. Novoformirani model nije dao dobre rezultate jer stopa nezaposlenosti nije statistički značajna varijabla. Iako postoji inverzan odnos između stope nezaposlenosti i stope inflacije, koeficijent determinacije je i dalje nizak, svega 14,18%.

Wald-ovim testom je dokazano da konstanta nije značajna za model, pa je isključena. Nakon toga, *Ramsey Reset* testom je potvrđeno da model nije dobro specificiran i da u njemu postoji problem autokorelacije grešaka. Nakon otklanjanja autokorelacije pokazalo se da su sve varijable iz modela statistički značajne. Istovremeno, došlo je do povećanja koeficijenta determinacije na 27,67%.

[77] Testovi se nalaze u Dodatku (*Tabela 8, Grafik 5, Tabela 9, Tabela 10, Tabela 11*, respektivno).

[78] Rezultati koeficijenta determinacije upućuju da, za ***Model 1***, nije potrebno ispitivati autokorelaciju, heteroskedastičnost, multikolinearnost.

Veza između stope inflacije i stope nezaposlenosti je statistički značajna i pozitivna, odnosno ukoliko stopa inflacije poraste za jedan procenat stopa nezaposlenosti će u prosjeku porasti za 0,41%.

Stabilnost modela je testirana grafičkim prikazom rekurzivnih reziduala, gdje je utvrđeno da postoji prekid u septembru 2016. godine (parlamentarni izbori), pa je za taj period uvedena vještačka varijabla, V_{2016m9}, što je uticalo na povećanje koeficijenta determinacije na 31,48%. *Redundant Variable Test*-om je potvrđeno da su sve nezavisne promjenljive u modelu opravdano uvedene i relevantne, osim V_1, pa je otklonjena iz modela (***Model 2***). Ocjena ***Modela 2*** je sljedeća: $lst_inf_intpol = 0{,}37*lst_n - 0{,}41*V_2 + 0{,}51*lst_inf_int(-1) + 2.03*V_{2016m9}$. Sprovedenim ekonometrijskim testovima potvrđeno je da ne postoji problem autokorelacije i heteroskedastičnosti grešaka, kao i da multikolinearnost nije izražena, dok reziduali imaju normalnu raspodjelu. Nakon toga, uzorak je proširen do januara 2022. godine (što je dodatnih 37 opservacija), i uvedena vještačka varijabla V_3, kojom su obuhvaćene promjene koje je izazvala COVID pandemija. Međutim, model nije pokazao veliku promjenu, procenat objašnjenosti je ostao skoro pa isti (31,67%). Grafičkim prikazom rekurzivnih reziduala utvrđeno je da postoje prekidi u septembru 2020. (parlamentarni izbori) i januaru 2022. godine (početak implementacije programa *Evropa sad*), pa su u model uvedene vještačke varijable za te periode (V_{2020m9} i V_{2022m1}), što je uticalo na povećanje koeficijenta determinacije na 36,56% (***Model 3)***. Ocjena ***Modela 3*** je: $lst_inf_intpol = 0{,}42*lst_n + 0{,}42*V_1 - 0{,}39*V_2 - 0{,}26*V_3 + 0{,}43*lst_inf_intpol(-1) + 1{,}99*V_{2016m9} + 1{,}58*V_{2020m9} + 1{,}71*V_{2022m1}$. U ***Tabeli 30.*** su dati sumirani podaci za analizirane modele. Primjetno je da, uvođenje dodatnih varijabli kao i povećanje uzorka, utiču na poboljšanje rezultata u ocijenjenim modelima. Zabilježen je rast koeficijenta determinacije, dok je ekonometrijskim testovima dokazano da nijedna od pretpostavki klasičnog lineranog regresionog modela nije narušena. Takođe, koeficijent uz nezavisnu varijablu sugeriše da postoji statistički značajna i negativna veza između stope inflacije i stope nezaposlenosti u ***Modelu 1***, dok je u ***Modelu 2*** i ***3*** ta veza statistički značajana i pozitivna.

Tabela 30*: Sumarni rezultati ocijenjenih modela*

Modeli	*Analizirani vremenski period*	*Koeficijent i vjerov. uz lst_n*	*Vr.koef. determinacije (R^2)*	*Raspodjela reziduala*	*Autokorelacija*	*Heteroskedastičnost*	*Multikolinearnost*
*Model1**	2008m1-2018m12	-1,39 (p=0%)	5,40%	/	/	/	/
*Model2***	2008m1-2018m12	0,37 (p=0%)	30,15%	normalna raspodjela	ne (otklonjena)	ne	umjerena (1.06-3.37)
*Model3****	2008m1-2022m1	0.42 (p=0%)	35,56%	normalna raspodjela	ne (otklonjena)	ne	umjerena (1.03-5.00)

**Ocjena Modela 1: $lst_inf_intpol = -3{,}78 - 1{,}39*lst_n$*

***Ocjena Modela 2: $lst_inf_intpol = 0{,}37*lst_n - 0{,}41*V_2 + 0{,}51*lst_inf_int(-1) + 2.03*V_{2016m9}$*

****Ocjena Modela 3: $lst_inf_intpol = 0{,}42*lst_n + 0{,}42*V_1 - 0{,}39*V_2 - 0{,}26*V_3 + 0{,}43*lst_inf_intpol(-1) + 1{,}99*V_{2016m9} + 1{,}58*V_{2020m9} + 1{,}71*V_{2022m1}$*

Granger-ov *test* kauzalnosti sugeriše da postoji jednosmjerna uzročnost od stope inflacije ka stopi nezaposlenosti. U proširenom modelu (sa više opservacija) – ***Model 3***, taj uticaj je prisutan na nivou od 2, 3 i 4 laga, u odnosu na ***Model 2,*** gdje je testom potvrđena kauzalnost isključivo na nivou od 2 laga.

Isti rezulatati su dobijeni i empirijskom analizom u Rumuniji, Albaniji, Makedoniji, Srbiji i Bosni i Hercegovini gdje je potvrđeno da, u nabrojanim zemljama Jugoistočne Evrope, u periodu od 1995. do 2015. godine, ne važi pravilo Filipsove krive, ali da postoji jednosmjerna kauzalnost između ispitivanih varijabli. (Lojanica, N., & Obradović, S.) Takođe, analizirana kriva u Hrvatskoj, u periodu od 2000. do 2016. godine (sa uključenim uticajem strukturnog loma u trećem kvartalu 2008. godine) ne ukazuje na empirijske dokaze o postojanju dugoročnog odnosa između stope inflacije i stope nezaposlenosti. (Recher, V., Matošec, M., Palić, P.) Banka saveznih rezervi Mineapolisa, u svom kvartalnom izvještaju iz 2001. godine, ističe da u prethodnih analiziranih 15 godina Filipsova kriva nije potvrđena. Štaviše, slabi teorijski i empirijski dokazi različitih inkarnacija modela navode na zaključak da predviđanje zasnovano na Filipsovoj krivoj treba napustiti.[79]

Ispitivanjem Filipsove krive u Baltičkim zemljama, u analizu je uključen ali nije dokazan, uticaj realnih graničnih troškova na inflaciju. Rezultati zapravo upućuju da je tekuća inflacija determinisana prethodnim stopama inflacije. (Dabušinskas, A., Kulikov, D.) U velikom broju radova, gdje je uključen uticaj *output gepa* i inflacionih očekivanja, dokazano je da se doprinosi boljoj ocjeni modela.[80] Činjenica je da na inflaciju utiče veći broj varijabli, i da je njihovo uključivanje u model opravdano, otuda je, u velikom broju radova, model Filipsove krive podložan različitim empirijskim specifikacijama, pa uzročno-posljedično i teorijskim tumačenjima. Iz tog razloga, posebnu pažnju treba obratiti kada se tako dobijeni rezultati interpretiraju i primjenjuju u realnim situacijama.

Prognoze ili upotreba ovog modela u kreiranju ekonomske politike ne pronalazi opravdanost zbog karakteristika koje je pokazao u procesu ocjenjivanja, kao i zbog vrijednosti koeficijenta determinacije, pa iz tog razloga ovaj korak nije sproveden. Dakle, teorija Filipsove krive nema empirijsku potvrdu u Crnoj Gori.

[79] Atkeson, A., & Ohanian, L. E. (2001). *Are Phillips curves useful for forecasting inflation?* Federal Reserve Bank of Minneapolis. Quarterly Review-Federal Reserve Bank of Minneapolis, 25(1), 2.
[80] Friedrich, C. (2016). *Global inflation dynamics in the postcrisis period: What explains the puzzles?* Economics Letters, 142(C); Jarociński, M., & Lenza, M. (2018). *An inflation-predicting measure of the output gap in the Euro area*. Journal of Money, Credit and Banking, 50(6).

ZAKLJUČAK

Četiri najznačajnija makroekonomska cilja, čijem ispunjenju teži svaka država da bi imala zdravu ekonomiju i konkurentsku poziciju na globalnom tržištu, su: održavanje inflacije na niskom ili umjerenom nivou; postizanje što niže stope nezaposlenosti, odnosno više stope zaposlenosti; stabilan privredni rast i uravnotežen spoljnotrgovinski i platni bilans. Postizanje navedenih makroekonomskih ciljeva je i više nego poželjno u jednom makroekonomskom sistemu. Iz tog razloga, u ovom radu, je istaknut odnos stope inflacije i stope nezaposlenosti, ali bez namjere da se umanji značaj preostala dva makroekonomska indikatora.

Puna zaposlenost, kao jedan od četiri osnovna makroekonomska cilja, bi značila i potpunu upotrebu raspoloživih kapaciteta, pa samim tim i rast životnog standarda, što bi uzročno-posljedično vodilo blagostanju jedne ekonomije. Međutim, kako nezaposlenost predstavlja ozbiljan problem razvijenih zemalja, nerazvijene ekonomije su još više pogođene, pa nije iznenađujuće što je i u Crnoj Gori problem nezaposlenosti stalno u fokusu kako ekonomskih istraživača, tako i kreatora ekonomske politike.

Sa druge strane, stopa inflacije koja se ogleda kroz porast opšteg nivoa cijena dobara i usluga, za evropske zemlje predstavlja veliki problem. Monetarna politika Evropske centralne banke nalaže da kamatne stope budu više, što dovodi do male tražnje i visoke nezaposlenosti. Suština ovakve monetarne politike jeste da se inflacija održava na niskom nivou, zbog prethodnog negativnog iskustva. Teško je održavati stopu inflacije na niskom nivou, a da pritom ne dođe do recesije i porasta nezaposlenosti. Iz tog razloga se nosioci makroekonomske politike uvijek nalaze pred dilemom izbora odgovarajućeg cilja, jer ostvarenje jednog ometa realizaciju drugog.

Ono što teorijski spaja ova dva bitna makroekonomska fenomena jeste model Filipsove krive, zato je rad podijeljen na tri dijela. U prvom dijelu je posvećena pažnja proučavanju značaja i razvoja Filipsove krive kroz vrijeme, što znači da je data teorijska podloga na osnovu koje se formira analizirani model. U drugom dijelu rada dat je osvrt na značaj i principe ekonometrijskog modeliranja i analizu vremenskih serija da bi se na pravilan način matematički specificirao, ocijenio i izabrao odgovarajući linearni regresioni model, u cilju njegove upotrebe za predviđanje, dok su u trećem dijelu rada primijenjena sva teorijska saznanja da bi se izvršila praktična ocjena modela na realnim podacima.

Rezultati istraživanja sugerišu da model Filipsove krive ne važi na tržištu Crne Gore za posmatrani period, od 2008. do 2022. godine, ali da postoji jednosmjerna kauzalnost, koja ukazuje da promjene u stopi inflacije uzrokuju promjene u stopi nezaposlenosti u kratkom roku. Slični rezultati su dobijeni i empirijskim analizama u drugim tranzicionim ekonomijama. Cilj svih tranzicionih zemalja, pa tako i Crne Gore, jeste povećanje privredne aktivnosti i zaposlenosti uz

istovremeno održavanje stabilne i niske stope inflacije. Kako ni u domaćoj ni u inostranoj literaturi nije postignut konsenzus o postojanju Filipsove krive, rezultati svih istraživanja se moraju uzeti sa rezervom prilikom njihove primjene u kreiranju ekonomske politike.

Zaključno, prilikom tumačenja rezultata modela za crnogorsko tržište, u obzir se mora uzeti jednostavnost analiziranog modela, kratak posmatrani vremenski period, nepreciznost u mjerenju posmatranih varijabli, s obzirom na problem sive ekonomije. Takođe, model je moguće proširiti dodatnim varijablama i uvećati broj ispitivanih opservacija, što predstavlja odličnu podlogu za sva dalja istraživanja modela Filipsove krive u Crnoj Gori.

LITERATURA

Knjige:

1. Anderson, D. R., Sweeney, D. J., Williams, T. A., Camm, J. D., & Cochran, J. J. (2012). *Quantitative Methods for Business (Book Only)*. Cengage Learning.
2. Attwood, Thomas. The Remedy; or, Thoughts on the Present Distresses. Second edition, with additions. London: 1816.
3. Babić, M. (2007). Makroekonomija, 15. Dopunjeno i izmijenjeno izdanje. *Mate doo, Zagreb*.
4. Burda, M., & Viploš, Č. (2012). *Makroekonomija*: evropski udžbenik, prevod 5. izd. Ekonomski fakultet, Centar za izdavačku delatnost, Beograd.
5. Chatfield, C. (2016). *The analysis of time series: an introduction*. CRC press.
6. Ćirović, M. (1989). *Monetarna ekonomija*. European centre for peace and development University for peace, Standing secretariat WSBM.
7. Diebold, F. X. (2001). Elements of forecasting.
8. Dimitrijević, B., Fabris, N., Vladušić, L., Radović, M., & Jandrić, M. (2016). Ekonomska politika–regionalni aspekti. *Economic policy–regional aspects]. Belgrade: Faculty of Economics*.
9. Domančić, P., & Nikolić, N. (1994). Monetarne financije i financiranje razvoja. *Ekonomski fakultet u Splitu, Sveučilište u Splitu, Split*.
10. Dušanić, J. B. (2009). *Hiperinflacija: da li nas istorija nečemu uči*. Beogradska poslovna škola.
11. Frederic, M. S. (2006). Monetarna ekonomija, bankarstvo i finansijska tržišta. *Data status, Beograd*.
12. Greene, W. H. (2003). Econometric Analysis, Prentice Hall. *New Jersey*, 16.
13. Hamid, A., & Miomir, J. (2005). „Makroekonomija“.
14. Hamilton, J. D. (1994). *Time series analysis* (Vol. 2). Princeton: Princeton university press.
15. Hume, D. (1752). *Political discourses*. R. Fleming.
16. Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: principles and practice*. OTexts.
17. Ivić, M., &Mitić, B. MAKROEKONOMIJA I GLOBALNI IZAZOVI.
18. Jakšić, M. (2005). *Osnovi makroekonomije*. Centar za izdavačku delatnost Ekonomskog fakulteta.
19. Jakšić, M., & Praščević, A. (2010). Politička makroekonomija. *Beograd: Ekonomski fakultet Univerziteta u Beogradu*.
20. Jovičić, M., & Mitrović, R. D. (2011). *Ekonometrijski metodi i modeli*. Univerzitet u Beogradu, Ekonomski fakultet.
21. Kacapyr, E. (1996). *Economic forecasting: the state of the art*. ME Sharpe.
22. Kovačić, Z. J. (1998). *Analiza vremenskih serija*. Ekonomski fakultet.
23. Mankiw, G. N. (2006). Osnove ekonomije, III izdanje, Mate, Zagreb. *Marušić, M., Vranešević*.
24. Mann, P. S. (2007). *Introductory statistics*. John Wiley & Sons

25. McConnell, C. R., Brue, S. L., & Flynn, S. M. (2009). *Economics: Principles, problems, and policies*. Boston McGraw-Hill/Irwin.
26. Miškin, F. S., Lalović, B., Erić, D., Živković, B., & Ilić, D. (2006). *Monetarna ekonomija, bankarstvo i finansijska tržišta*. Data status.
27. Mladenović, Z., & Nojković, A. (2008). *Analiza vremenskih serija: primeri iz srpske privrede*. Centar za izdavačku delatnost Ekonomskog fakulteta.
28. Mladenovic, Z., & Nojkovic, A. (2012). Primenjena analiza vremenskih serija (Applied time series analysis). *Centar Za Izdavacku Delatnost Ekonomskog Fakulteta U Beogradu*.
29. Mladenović, Z., & Petrović, P. (2007). *Uvod u ekonometriju*. Centar za izdavačku delatnost Ekonomskog fakulteta.
30. Molnar, A. T. (2010). *Economic forecasting*. Nova Science Publishers.
31. Olivier, B. (2005). Makroekonomija.
32. Radman Funarić, M., „Uvod u gospodarsku statistiku“, Veleučilište u Požegi, Požega, 2018.
33. Rakčević-Glišević, N., Razvoj i osnove savremene ekonomske misli”, Podgorica, 2004, str. 137-138.
34. Sekulović, M., Kitanović, D., & Cvetanović, S. (1997). *Makroekonomija*. Zavod za udžbenike I nastavna sredstva.
35. Sharpe, N. D., De Veaux, R. D., & Velleman, P. F. (2015). *Business statistics*. Pearson.
36. Stojanović, I., Gavrilović, M. (2005). *Međunarodni ekonomski odnosi*. Megatrend univerzitet primenjenih nauka.
37. Živković, A., & Kožetinac, G. (2006). *Monetarna ekonomija: teorijsko-metodološke osnove efikasne monetarne politike*. Centar za izdavačku delatnost Ekonomskog fakulteta.

Naučni članci:

1. “Of Hume, Thornton, the Quantity Theory, and the Phillips Curve.” Economic Review, Federal Reserve Bank of Richmond 68 (November/ December 1982) : 13-18.
2. Atkeson, A., & Ohanian, L. E. (2001). Are Phillips curves useful for forecasting inflation? *Federal Reserve Bank of Minneapolis. Quarterly Review-Federal Reserve Bank of Minneapolis*, *25*(1), 2.
3. Benić, Đ. (2014). POVIJEST RAZVOJA TEORIJE O ODNOSU IZMEĐU INFLACIJE I NEZAPOSLENOSTI. *Ekonomska misao i praksa*, (2), 411-430.
4. Borozan, Đ. (2002). Od Phillipsove krivulje do NAIRU. *Ekonomski vjesnik: Review of Contemporary Entrepreneurship, Business, and Economic Issues*, *13*(1-2), 83-96.
5. Brissimis, S. N., &Magginas, N. S. (2008). Inflation forecasts and the New Keynesian Phillips curve. *International Journal of Central Banking*, *4*(2), 1-22.
6. BUKVIĆ, R. (1972). Inflacija i nezaposlenost. *Ekonomika*, *6*, 1-18.
7. Chletsos, M., Drosou, V., &Roupakias, S. (2016). Can Phillips curve explain the recent behavior of inflation? Further evidence from USA and Canada. *The Journal of Economic Asymmetries*, *14*, 20-28.
8. Daoud, J. I. (2017, December). Multicollinearity and regression analysis. In *Journal of Physics: Conference Series* (Vol. 949, No. 1, p. 012009). IOP Publishing.
9. Dimitrijević, B. (2015). Phillips curve in welfare economics and game theory. *Poslovna ekonomija*, *9*(1), 9-34.

10. Dimitrijević, B. S. (2011). The return of the Phillips curve: Relationship between inflation and unemployment in developed countries in the period 1970-2000. *Poslovnaekonomija*, *5*(2), 59-81.
11. Družić, I., Tica, J., & Mamić, A. (2006). The challenge of application of Phillips curve: the case of Croatia. *Zagreb international review of economics & business*, (1), 45-59.
12. Elliot, B. (2015). The Relationship between Inflation and Unemployment in Ghana: Analysis of the Philips Curve. *African Journal of Economic Review*, *3*(2), 117-124.
13. Fisher, I. (1973). I Discovered the Phillips Curve:" A Statistical Relation between Unemployment and Price Changes". *Journal of Political Economy*, *81*(2, Part 1), 496-502.
14. Friedman, M. (1976). INFLATION AND UNEMPLOYMENT Nobel Memorial Lecture, December 13, 1976.
15. Friedrich, C. (2016). Global inflation dynamics in the postcrisis period: What explains the puzzles? Economics Letters, 142(C), 31-34. doi:10.1016/j.econlet.2016.02.032
16. Gordon, R. J. (2011). The history of the Phillips curve: Consensus and bifurcation. *Economica*, *78*(309), 10-50.
17. Hines, A. G. (1968). Unemployment and the Rate of Change of Money Wage Rates in the United Kingdom 1862-1963: A Reappraisal. *The Review of Economics and Statistics*, 60-67.
18. HUME AND ENDOGENOUS MONEY, Maria Pia Paganelli Yeshiva University, Eastern Economic Journal, Vol. 32, No. 3, Summer 2006, pp. 533-547.
19. Humphrey, T. M. (1985). The early history of the Phillips curve. *Economic review*, *71*(5), 17-24.
20. Humphrey, Thomas M., Two Views of Monetary Policy: The Attwood-Mill Debate Revisited (1977). FRB Richmond Economic Review, Vol. 63, No. 5, September/October 1977, pp. 14-22, Available at SSRN: https://ssrn.com/abstract=2116450
21. Jarociński, M., & Lenza, M. (2018). An inflation-predicting measure of the output gap in the Euro area. Journal of Money, Credit and Banking, 50(6), 1189-1224. doi:10.1111/jmcb.12496
22. Kožul, N. (2012). Inflation forecasting: A comparison between conventional Phillips curves and new Keynesian-Phillips curve. *Bankarstvo*, *41*(6), 72-83.
23. Lacker, J. M., & Weinberg, J. A. (2007). Inflation and unemployment: a layperson's guide to the Phillips curve. *FRB Richmond Economic Quarterly*, *93*(3), 201-227.
24. Laseen, S., & Sanjani, M. T. (2016). “Did the global financial crisis break the US Phillips Curve?” IMF Working Paper WP/16/126.
25. Lindé, J. (2005). Estimating New-Keynesian Phillips curves: A full information maximum likelihood approach. *Journal of Monetary Economics*, *52*(6), 1135-1149.
26. Lipsey, R. G. (1960). The relation between unemployment and the rate of change of money wage rates in the United Kingdom, 1862-1957: a further analysis. *Economica*, 1-31.
27. Lojanica, N., & Obradović, (2019) S. POVEZANOST INFLACIJE, NEZAPOSLENOSTI I EKONOMSKOG RASTA-EMPIRIJSKA ANALIZA NA PRIMERU ZEMALJA JUGOISTOČNE EVROPE.
28. Mankiw, N. G. (2001). The inexorable and mysterious tradeoff between inflation and unemployment. *The Economic Journal*, *111*(471), 45-61.
29. Mathews, Don (2019). *DID IRVING FISHER REALLY DISCOVER THE PHILLIPS CURVE? Journal of the History of Economic Thought, 41(2), 255–271.*

30. Motyovszki, G. E. R. G. Ő. (2013). The evolution of the Phillips curve concepts and their implications for economic policy. *History of Economic Thought", Term Paper, Central European University*.
31. Mouhammed, A. H. (2006). Instability of capitalism inflation, unemployment, and business cycles. *Zbornik radova Ekonomskog fakulteta u Rijeci: časopis za ekonomsku teoriju i praksu*, *24*(2), 165-184.
32. Palley, T. (2012). The economics of the Phillips curve: Formation of inflation expectations versus incorporation of inflation expectations. *Structural Change and Economic Dynamics*, *23*(3), 221-230.
33. Pejaković, G. (2010). INFLATION AND UNEMPLOYMENT: PHILLIPS REGULARITY IN THE EU. *ZbornikRadova*, (30).
34. Phelps, E. S. (1969). The new microeconomics in inflation and employment theory. *The American Economic Review*, *59*(2), 147-160.
35. Philips, A. W. (1958). The relationship between unemployment and the rate of change of money wage rates in the United Kingdom, 1861-1957. *Economica*, 25 (November), 283-299.
36. Popovic, G. (2010). Inflation and unemployment: Phillips regularity in the EU. *Sarajevo Business and Economics Review*, *30*, 370.
37. Recher, V., Matošec, M., & Palić, P. (2017). ANALIZA ODNOSA NEZAPOSLENOSTI I INFLACIJE U UVJETIMA KRIZE: PRIMJER HRVATSKE. *Ekonomski pregled*, *68*(1), 32-58.
38. Rudd, J., & Whelan, K. (2005). New tests of the new-Keynesian Phillips curve. *Journal of Monetary Economics*, *52*(6), 1167-1181.
39. Samuelson, P. A., & Solow, R. M. (1960). Analytical aspects of anti-inflation policy. *The American Economic Review*, *50*(2), pp. 177-194.
40. Samuelson, P. A., & Solow, R. M. (1960). Analytical aspects of anti-inflation policy. *The American Economic Review*, *50*(2), pp. 177-194.
41. Schwarzer, J. A. (2012). AW Phillips and his curve: Stabilisation policies, inflation expectations and the 'menu of choice'. *The European Journal of the History of Economic Thought*, *19*(6), 976-1003.
42. Schwarzer, J. A. (2012). AW Phillips and his curve: Stabilisation policies, inflation expectations and the 'menu of choice'. *The European Journal of the History of Economic Thought*, *19*(6), 976-1003.
43. Stevens, A. (2013). What inflation developments reveal about the Phillips curve: Implications for monetary policy. *National Bank of Belgium Economic Review*, 67-76.
44. The origins of the Phillips Curve, William F. Mitchell, February 1999, Centre of Full Employment and Equity, The University of Newcastle, Working Paper No. 99-02

Internet sajtovi:

www.cb-cg.org
ec.europa.eu
www.statista.com
www.monstat.org
www.zzzcg.me
www.ecb.europa.eu

DODATAK

***Tabela 1**: Prošireni Dickey-Fuller-ov test za logaritmovanu i interpolisanu seriju stopa inflacije (period: januar 2008.-decembar 2018.)*

Null Hypothesis: LST_INF_INTPOL has a unit root
Exogenous: Constant
Lag Length: 0 (Automatic - based on SIC, maxlag=12)

		t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic		-6.706459	0.0000
Test critical values:	1% level	-3.481217	
	5% level	-2.883753	
	10% level	-2.578694	

***Tabela 2**: Prošireni Dickey-Fuller-ov test za logaritmovanu seriju stopa nezaposlenosti (period: januar 2008.-decembar 2018.)*

Null Hypothesis: LST_N has a unit root
Exogenous: Constant
Lag Length: 12 (Automatic - based on SIC, maxlag=12)

		t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic		-3.401386	0.0128
Test critical values:	1% level	-3.486064	
	5% level	-2.885863	
	10% level	-2.579818	

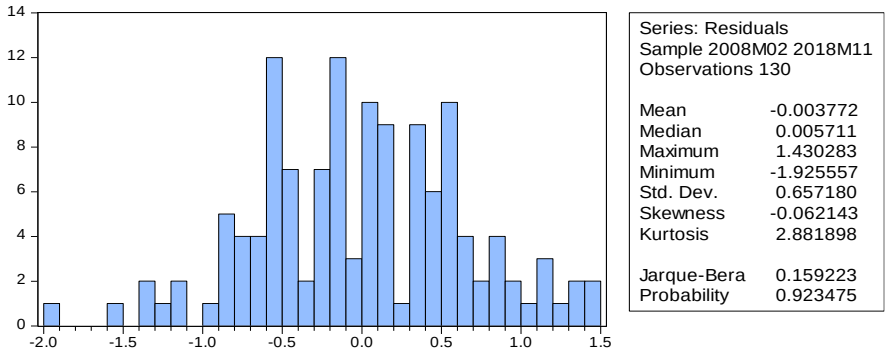

***Grafik 1**: Histogram reziduala modela: lst_inf_intpol = 0,37980*lst_n + 0,384280*V_1 - 0,406531*V_2 + 0,468701*lst_inf_intpol(-1) + 2,009955*V_{2016m9}*

***Tabela 3**: Testiranje autokorelacije: Breusch-Godfrey Test za model:*
*lst_inf_intpol = 0,37980*lst_n + 0,384280*V_1 - 0,406531*V_2 + 0,468701*lst_inf_intpol(-1) + 2,009955*V_{2016m9}*

Breusch-Godfrey Serial Correlation LM Test:

F-statistic	0.622609	Prob. F(2,123)	0.5382
Obs*R-squared	1.298622	Prob. Chi-Square(2)	0.5224

Test Equation:
Dependent Variable: RESID
Method: Least Squares
Sample: 2008M02 2018M11
Included observations: 130
Presample missing value lagged residuals set to zero.

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LST_N	0.021355	0.141743	0.150658	0.8805
V1	0.033019	0.272422	0.121206	0.9037
V2	-0.014640	0.193672	-0.075590	0.9399
LST_INF_INTPOL(-1)	-0.029876	0.195020	-0.153195	0.8785
V2016M9	-0.017314	0.692969	-0.024985	0.9801
RESID(-1)	0.078805	0.206359	0.381882	0.7032
RESID(-2)	-0.074579	0.125681	-0.593403	0.5540

R-squared	0.009989	Mean dependent var	-0.003772
Adjusted R-squared	-0.038304	S.D. dependent var	0.657180
S.E. of regression	0.669648	Akaike info criterion	2.088213
Sum squared resid	55.15669	Schwarz criterion	2.242619
Log likelihood	-128.7338	Hannan-Quinn criter.	2.150953
Durbin-Watson stat	2.005075		

***Tabela 4**: Testiranje heteroskedastičnosti: Glejser test za izabrani model:*
*lst_inf_intpol = 0,37980*lst_n + 0,384280*V_1 - 0,406531*V_2 + 0,468701*lst_inf_intpol(-1) + 2,009955*V_{2016m9}*

Heteroskedasticity Test: Glejser

F-statistic	1.529094	Prob. F(5,124)	0.1855
Obs*R-squared	7.549906	Prob. Chi-Square(5)	0.1828
Scaled explained SS	7.048067	Prob. Chi-Square(5)	0.2171

Test Equation:
Dependent Variable: ARESID
Method: Least Squares
Sample: 2008M02 2018M11
Included observations: 130

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.634581	0.601679	1.054684	0.2936
LST_N	-0.012538	0.326394	-0.038413	0.9694
V1	-0.024117	0.145234	-0.166059	0.8684
V2	-0.104347	0.121703	-0.857392	0.3929
LST_INF_INTPOL(-1)	0.085605	0.045472	1.882601	0.0621
V2016M9	-0.353904	0.398802	-0.887416	0.3766

R-squared	0.058076	Mean dependent var	0.526666
Adjusted R-squared	0.020095	S.D. dependent var	0.390349
S.E. of regression	0.386407	Akaike info criterion	0.981204
Sum squared resid	18.51449	Schwarz criterion	1.113552
Log likelihood	-57.77825	Hannan-Quinn criter.	1.034981
F-statistic	1.529094	Durbin-Watson stat	1.581929
Prob(F-statistic)	0.185522		

***Tabela 5**:* Testiranje multikolinearnosti za ocijenjeni model: *lst_inf_intpol = 0,37980*lst_n + 0,384280*V_1 - 0,406531*V_2 + 0,468701*lst_inf_intpol(-1) + 2,009955*V_{2016m9}*

Variance Inflation Factors
Sample: 2008M01 2018M12
Included observations: 130

Variable	Coefficient Variance	Uncentered VIF
LST_N	0.004373	4.118294
V1	0.060740	1.226469
V2	0.029506	1.257768
LST_INF_INTPOL(-1)	0.005965	4.031253
V2016M9	0.472912	1.061005

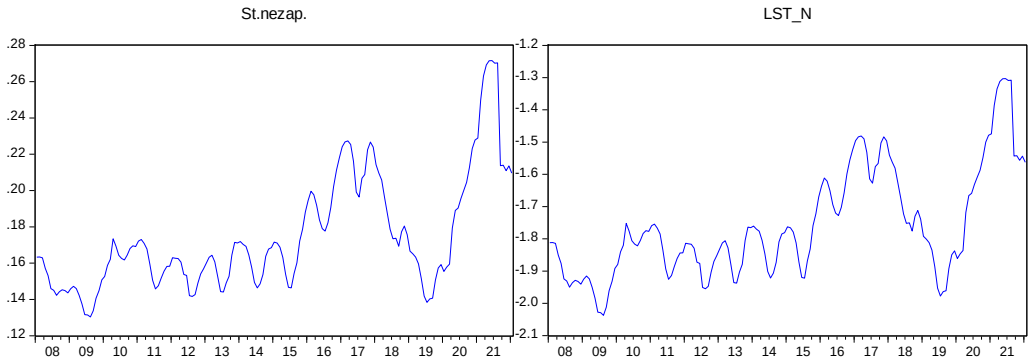

***Grafik 2**: Grafički prikaz originalne i logaritmovane serije stopa nezaposlenosti (period: 2008m01-2022m1)*

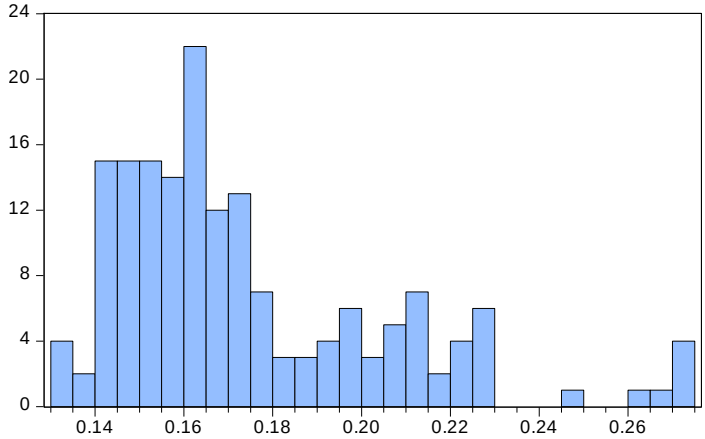

Series: ST_N
Sample 2008M01 2022M01
Observations 169

Mean	0.174507
Median	0.164451
Maximum	0.271624
Minimum	0.130399
Std. Dev.	0.031281
Skewness	1.238118
Kurtosis	4.179911
Jarque-Bera	52.98101
Probability	0.000000

***Grafik 3**: Histogram serije stopa nezaposlenosti sa pratećom deskriptivnom statistikom*

***Tabela 6**: Prošireni Dickey-Fuller-ov test stacionarnosti za logaritmovanu stopu nezaposlenosti (period: 2008m1-2022m1)*

Null Hypothesis: LST_N has a unit root
Exogenous: Constant
Lag Length: 1 (Automatic - based on SIC, maxlag=13)

		t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic		-2.392375	0.1454
Test critical values:	1% level	-3.469691	
	5% level	-2.878723	
	10% level	-2.276010	

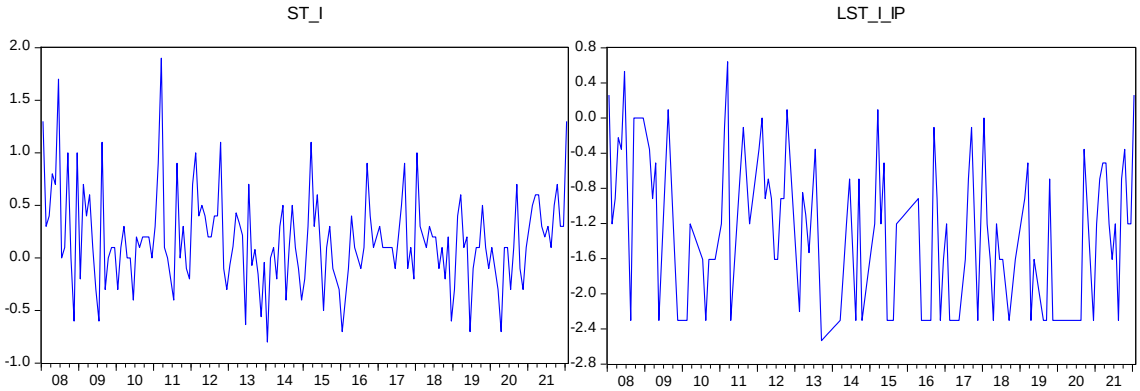

***Grafik 3**: Grafički prikaz originalne i logaritmovane serije stopa inflacije (period: 2008m01-2022m1)*

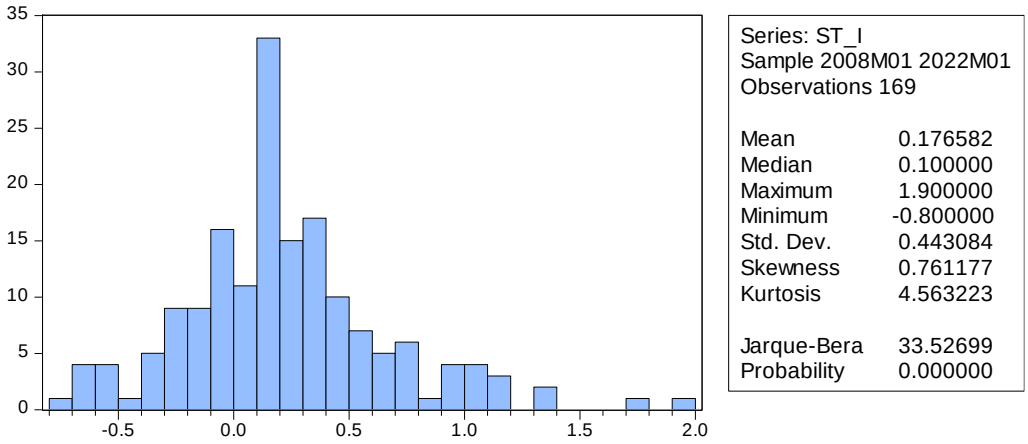

***Grafik 4**: Histogram serije stopa inflacije sa pratećom deskriptivnom statistikom*

***Tabela 7**: Prošireni Dickey-Fuller-ov test stacionarnosti za logaritmovanu seriju stopa inflacije (period: 2008m01-2022m01)*

Null Hypothesis: LST_I_IP has a unit root
Exogenous: Constant
Lag Length: 0 (Automatic - based on SIC, maxlag=13)

		t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic		-7.495546	0.0000
Test critical values:	1% level	-3.469451	
	5% level	-2.878618	
	10% level	-2.575954	

***Tabela 8**: Redundant variable Test za lst_n, V_1, V_2, V_3, lst_inf_intpol(-1), V_{2016m9}, V_{2020m9}, V_{2022m1}*

Redundant Variables Test
Specification: LST_INF_INTPOL LST_N V1 V2 V3 LST_INF_INTPOL(-1) V2016M9 V2020M9 V2022M1 V2022M1
Redundant Variables: LST_N

	Value	df	Probability
t-statistic	6.696922	160	0.0000
F-statistic	44.84877	(1, 160)	0.0000
Likelihood ratio	41.51250	1	0.0000

Redundant Variables: V1

	Value	df	Probability
t-statistic	2.358908	160	0.0195
F-statistic	5.564449	(1, 160)	0.0195
Likelihood ratio	5.743369	1	0.0166

Redundant Variables: V2

	Value	df	Probability
t-statistic	2.383118	160	0.0183
F-statistic	5.679250	(1, 160)	0.0183
Likelihood ratio	5.859819	1	0.0155

Redundant Variables: V3

	Value	df	Probability
t-statistic	2.055290	160	0.0415
F-statistic	4.224219	(1, 160)	0.0415
Likelihood ratio	4.377889	1	0.0364

Redundant Variables: LST_INF_INTPOL(-1)

	Value	df	Probability
t-statistic	6.360140	160	0.0000
F-statistic	40.45138	(1, 160)	0.0000
Likelihood ratio	37.86684	1	0.0000

Redundant Variables: V2016M9

	Value	df	Probability
t-statistic	3.001873	160	0.0031
F-statistic	9.011244	(1, 160)	0.0031
Likelihood ratio	9.204960	1	0.0024

Redundant Variables: V2020M9

	Value	df	Probability
t-statistic	2.411764	160	0.0170
F-statistic	5.816606	(1, 160)	0.0170
Likelihood ratio	5.999042	1	0.0143

Redundant Variables: V2022M1

	Value	df	Probability
t-statistic	2.616338	160	0.0097
F-statistic	6.845226	(1, 160)	0.0097
Likelihood ratio	7.037986	1	0.0080

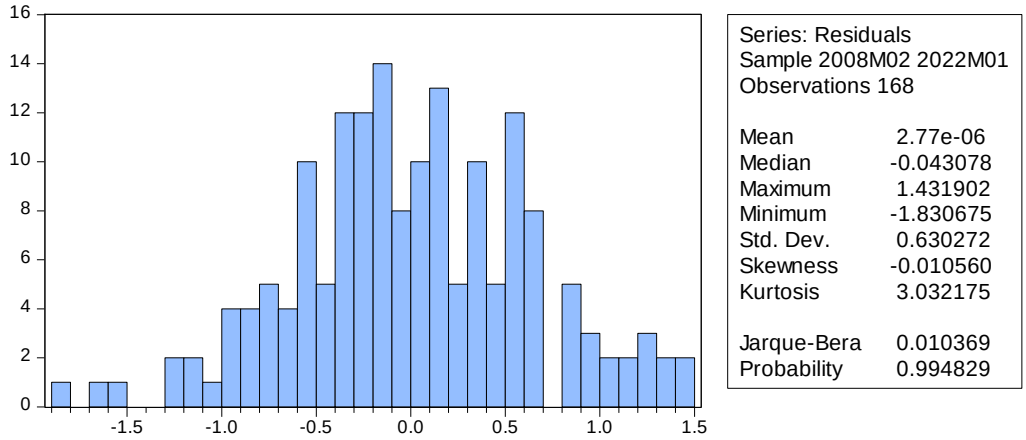

***Grafik 5**: Histogram reziduala ocijenjenog **Modela 3**: lst_inf_intpol = 0,42*lst_n + 0,41*V_1 - 0,39*V_2 - 0,26*V_3 + 0,43*lst_inf_intpol(-1) + 1.99*V_{2016m9} + 1.58*V_{2020m9} + 1.71*V_{2022m1}*

***Tabela 9**: Testiranje autokorelacije: Breusch-Godfrey Test za ocijenjeni **Model 3**:*
*lst_inf_intpol = 0,42*lst_n + 0,41*V_1 - 0,39*V_2 - 0,26*V_3 + 0,43*lst_inf_intpol(-1) + 1.99*V_{2016m9} + 1.58*V_{2020m9} + 1.71*V_{2022m1}*

Breusch-Godfrey Serial Correlation LM Test:

F-statistic	0.448074	Prob. F(2,158)	0.6397
Obs*R-squared	0.947492	Prob. Chi-Square(2)	0.6227

Test Equation:
Dependent Variable: RESID
Method: Least Squares
Sample: 2008M02 2022M01
Included observations: 168
Presample missing value lagged residuals set to zero.

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LST_N	0.036782	0.153743	0.239242	0.8112
V1	0.042290	0.240982	0.175490	0.8609
V2	-0.020727	0.183376	-0.113030	0.9102
V3	-0.017054	0.147119	-0.115916	0.9079
LST_INF_INTPOL(-1)	-0.049003	0.199157	-0.246052	0.8060
V2016M9	-0.022712	0.668389	-0.033980	0.9729
V2020M9	-0.021954	0.658963	-0.033316	0.9735
V2022M1	-0.010117	0.656990	-0.015398	0.9877
RESID(-1)	0.085222	0.211383	0.403162	0.6874
RESID(-2)	-0.042907	0.116132	-0.369470	0.7123

R-squared	0.005640	Mean dependent var	2.77E-06
Adjusted R-squared	-0.051001	S.D. dependent var	0.630272
S.E. of regression	0.646144	Akaike info criterion	2.022091
Sum squared resid	65.96542	Schwarz criterion	2.208042
Log likelihood	-159.8557	Hannan-Quinn criter.	2.097559
Durbin-Watson stat	1.996195		

***Tabela 10:** Testiranje heteroskedastičnosti: Glejser test za ocijenjeni **Model 3**:*
*lst_inf_intpol = 0,42*lst_n + 0,41*V_1 - 0,39*V_2 - 0,26*V_3 + 0,43*lst_inf_intpol(-1) + 1.99*V_{2016m9} + 1.58*V_{2020m9} + 1.71*V_{2022m1}*

Heteroskedasticity Test: Glejser

F-statistic	1.397229	Prob. F(8,159)	0.2015
Obs*R-squared	11.03478	Prob. Chi-Square(8)	0.1997
Scaled explained SS	10.77954	Prob. Chi-Square(8)	0.2145

Test Equation:
Dependent Variable: ARESID
Method: Least Squares
Sample: 2008M02 2022M01
Included observations: 168

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.664442	0.400861	1.657535	0.0994
LST_N	0.023431	0.222942	0.105100	0.9164
V1	0.021602	0.106982	0.201919	0.8402
V2	-0.079088	0.109302	-0.723568	0.4704
V3	-0.018090	0.085821	-0.210792	0.8333
LST_INF_INTPOL(-1)	0.079131	0.040588	1.949615	0.0530
V2016M9	-0.364310	0.392701	-0.927702	0.3550
V2020M9	-0.426954	0.388350	-1.099405	0.2733
V2022M1	-0.514468	0.387540	-1.327521	0.1862

R-squared	0.065683	Mean dependent var	0.497692
Adjusted R-squared	0.018674	S.D. dependent var	0.384788
S.E. of regression	0.381178	Akaike info criterion	0.960985
Sum squared resid	23.10223	Schwarz criterion	1.128340
Log likelihood	-71.72275	Hannan-Quinn criter.	1.028906
F-statistic	1.397229	Durbin-Watson stat	1.623835
Prob(F-statistic)	0.201471		

***Tabela 11**: Reziltati VIF za ocijenjeni Model 3*

Variance Inflation Factors
Sample: 2008M01 2022M01
Included observations: 168

Variable	Coefficient Variance	Uncentered VIF
LST_N	0.003956	5.009317
V1	0.031218	1.355263
V2	0.027238	1.248155
V3	0.016678	1.407844
LST_INF_INTPOL(-1)	0.004701	4.690266
V2016M9	0.439560	1.060145
V2020M9	0.429953	1.036974
V2022M1	0.427657	1.031438