STATISTIČKA ANALIZA TEČAJA EURA OD 1995. DO 2015.

Gabelica, Ante

Undergraduate thesis / Završni rad

2016

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:124:680150

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

zir.nsk.hr

UNIVERSITY OF SPLIT

dabar

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET

ZAVRŠNI RAD

STATISTIČKA ANALIZA TEČAJA EURA OD 1995. DO 2015.

Mentor:
prof. dr. sc. Ante Rozga

Student:
Ante Gabelica, 1132458

Split, rujan 2016.

SADRŽAJ

1. UVOD 3

1.1. Definicija problema 3

1.2. Ciljevi rada 4

1.3. Metode rada 4

1.4. Struktura rada 4

2. STATISTIČKE METODE 6

2.1. Pojam statistike i njenih metoda 6

2.2. Odabrani statistički testovi 9

3. DEVIZNI TEČAJ 16

3.1. Pojam i formiranje deviznog tečaja 16

3.2. Kretanje tečaja Eura 17

4. STATISTIČKA ANALIZA TEČAJA EURA OD 1995. DO 2015. 22

4.1. Jednostavni linearni trend 22

4.2. Logaritamska parabola 26

4.3. Sezonske varijacije 30

5. ZAKLJUČAK 58

LITERATURA 60

POPIS TABLICA 61

POPIS GRAFIKONA 62

SAŽETAK 63

SUMMARY 63

1. UVOD

1.1. Definicija problema

Statistika se može navest kao skup koncepata, procedura i raznih pravila koji mogu koristiti:

- u razumijevanju metoda statistike
- i odlukama na temelju osnove podataka i rezultata statističkih metoda
- te u samom razumijevanju metoda statistike čiji je korisnički popis vrlo širok, on seže u ekonomiju, zdravstvo, politiku, itd.

Potrebna je kako bi određene podatke mogli transformirati mnogo lakše u cjelokupno znanje i informacije.

Statistika se dijeli na inferencijalnu i na deskriptivnu ili opisnu.
Inferencijalna statistika se temelji na uzorku, odnosno na dijelu jedinica statističkog skupa. Na temelju podataka o dijelu zaključuje se o svojstvima cjeline. Primjenom metoda inferencijalne statistike, a na temelju podataka realnog ili zamišljenog skupa, donose se zaključci o cjelini, odnosno o skupu.[1]

Dok se deskriptivna statistika temelji na konkretnim rezultatima dobivenim kakvim istraživanjima te mjerenjima obuhvaćajući tim cijeli statistički skup.

Statistika se, kao znanost, sastoji od koncepata, pravila i procedura koje pomažu u slijedećim aktivnostima:[2]

- u organizaciji brojčanih podataka u obliku tablica i grafikona,
- u razumijevanju statističkih metoda i
- u donošenju odluka na osnovi podataka i rezultata primjene statističkih metoda.

Dakle, prema svemu navedenom može se zaključiti da statistika, odnosno statističke metode omogućavaju prikaz, odnosno transformaciju podataka u informacije i znanje. Primjena

[1] Rozga. A., Grčić, B. (2000): Poslovna statistika, Veleučilište u Splitu, Split, str. 5.
[2] Hoffman, H.S. (1985.): Statistics Explained, University Press of America, Lanham.

statističkih metoda i analiza uvelike je široka te se najčešće koristi pri analiziranju ekonomije, politike, zdravstva i sl.

U ovom završnom radu analizirat će se kretanje i promjene tečajeva kune, britanske funte, američkog dolara i švicarskog franka, te kako promjene navedenih tečajeva utječu na euro. Istraživanje će obuhvatit vremensko razdoblje od 1995. godine do 2015. godine.

1.2. Ciljevi rada

Ciljevi ovog završnog rada su sljedeći:

- Istaknuti i opisati važnost statistike i statističkih metoda
- Teoretski prikazati osnove deviznog tečaja
- Analizirati kretanje tečaja eura u odnosu na kunu, britansku funtu, američki dolar i švicarski franak
- Prikazati trend kretanja i sezonskih varijacija izabranih varijabli

1.3. Metode rada

U ovom završnom radu korištene su sljedeće metode:

- Metoda prikupljanja podataka – najveći dio podataka prikupljen je pretraživanjem Interneta
- Metoda eksplanacije – objašnjavanje osnovnih pojmova
- Induktivna metoda – analizirajući pojedinačne podatke dolazi se do općih zaključaka
- Metode kompilacije – korištenje tuđih znanstvenih i istraživačkih radova i zaključaka
- Metoda obrade podataka – softverski program Statistica

1.4. Struktura rada

Ovaj završni rad podijeljen je na pet cjelina, uključujući uvod i zaključak.

U uvodnom dijelu rada opisan je problem istraživanja, te su navedeni ciljevi rada i metode korištene pri pisanju završnog rada.

U drugoj cjelini objašnjava se što je to statistika i statističke metode. Za što se koristi statistika te se opisuju osnovne statističke metode i testovi.

Treća cjelina rada pod nazivom „Devizni tečaj“ odnosi se na definiranje pojma deviznog tečaja, te se opisuje samo formiranje deviznih tečajeva. Osim navedenog, u ovom poglavlju prikazano je i kretanje tečaja Eura u odnosu na kunu, franak, funtu i dolar.

U četvrtom dijelu završnog rada provedena je statistička analiza kretanja tečaja Eura od 1995. godine do 2015. godine, te se prikazuju i objašnjavaju dobiveni rezultati analize.

Posljednji dio rada jest zaključak, u kojem se donose glavni zaključci o provedenim analizama kretanja tečaja eura u odnosu na kunu, franak, funtu i dolar.

2. STATISTIČKE METODE

2.1. Pojam statistike i njenih metoda

Statistika je grana znanosti koja u svrhu realizacije postavljenih ciljeva istraživanja organizirano prikuplja, odabire, prezentira, vrši i interpretira rezultate provedenih analiza masovnih podataka.[3]

Također, statistika je posebna znanstvena disciplina koja se bavi prikupljanjem, selekcijom, prezentacijom i analizom informacija ili podataka te izvođenjem zaključka na temelju tih podataka.[4]

Ona koristi brojne metode koje se koriste svugdje od zdravstva ekologije politike ekonomije te tako zauzima vodeću ulogu u samom postupku odlučivanja.

Statističke podatke analize aktivnosti gospodarstva i nekih njegovih odsječaka zbog odluka o eliminaciji jačanja cijena, čuvanja postojanosti tečaja i poticanju izvoza koriste nosioci ekonomske politike. Isto tako ne smijemo prestati voditi brigu oko statistike u mikroekonomiji.

Statistika se dijeli se na inferencijalnu i deskriptivnu.

Inferencijalna statistika temelji se na dijelu jedinica izabranih iz cjelovitog statističkog skupa, pomoću kojeg se uz primjenu odgovarajućih statističkih metoda i tehnika donose zaključci o čitavom statističkom skupu.[5]

Dok se deskriptivna ili opisna statistika zasniva na cjelokupnom sadržaju statističkog skupa, čiji se podaci prikupljaju organizirano, grupiraju, odabiru i prezentiraju krajnje raščlambe. Tako cijela prosta statistika bude razumljivija te se svede na jednostavniji oblik.

[3] Rozga, A., Grčić, B. (2010): Poslovna statistika Veleučilište u Splitu, Split, str. 1.
[4] Rozga, A. (2006): Statistika za ekonomiste. Ekonomski fakultet, Split, str. 1.
[5] Pivac, S. (2000): Statističke metode, Ekonomski fakultet, Split, str.11.

Statističke informacije, tehnike i metode služe da preko njih provodimo statističku analizu prirodnih te društvenih pojava. Razlikuju se dvije vrste pojava, a to su slučajne i masovne, kojima se bavi statistika kako bi u njima uočila zakonitosti.

Masovne pojave su pojave koje imaju jednu ili više zajedničkih obilježja. Tu cjelinu nazivamo statističkom masom.

Da bismo definirali pojmovno statistički skup potrebno je odrediti neki pojam svih elemenata u određenom skupu. Prostorno odrediti znači odrediti prostor na koji se odnosi ili kojem pripada neki njegov element. Vremenski odrediti statistički skup znači odrediti vremenski trenutak ili razdoblje kojim će se obuhvatiti svi elementi koji ulaze u statistički skup.[6]

Bilo koje statističko istraživanje mora sadržavati faze:

1. Organizirano prikupljanje statističkih podataka

Dvije moguće pogreške su ona slučajna i sistematska (krivi način mjerenja).Poželjno ih je ukloniti, a to se može postići samo dobrom organizacijom prikupljanja informacija, kontrolama ispravnosti informacija i dakako njihova točna obrada.

2. Grupiranje statističkih podataka

Grupiranjem statističkih podataka se dijeli statistički skup na više grupa ili pod skupova uz već neke od prije postavljene modalitete obilježja.

Pravila za grupiranje su sljedeća:

- jedan statistički element mora pripadati jednoj grupi
- svaki mora pripadati jednoj grupi

Taj broj elemenata statističkog skupa u određenoj grupi zove se apsolutna frekvencija, a skup parova pojedinog modaliteta promotrenog obilježja i apsolutnih frekvencija koje im već pripadaju nazivamo statističkim skupom. Vrste statističkog skupa su redoslijedne, numeričke, nominalne te još imamo vremenski statističke nizove.

[6] Pivac, S.: op. cit., str.11.

3. Tabelarno i grafičko prikazivanje statističkih podataka

Tabelarno i grafičko prikazivanje statističkih podataka je rješavanje surove statističke građe čiji je cilj cjelokupna i jasna prezentacija s kojom bi se mogli prezentirati rezultati provođenja prijašnjih faza. Statističke tablice su nezaobilazne u modernoj literaturi, one moraju sadržavati naslov, tekstualni dio, brojčani dio te izvor podataka.

Tekstualni dio sadržava dva dijela: zaglavlja i prestupaca i njihovih tumača. Brojčani dio sadrži niz polja u koja unosimo rezultate grupiranja podataka. Grafičkim prikazima sredstva se pokušava jednostavnim načinom prezentirati osnovno od statističkog niza. Imamo tri skupine prikaza, a to su površinski, poligon frekvencija i karto grami. Površinski su razni stupci, proporcionalni krugovi ili polukrugovi, kvadrati. Karto grame dijelimo na statističke i dijagramske karte te piktograme. Grafikon se sastoji od naslova, oznake mjernih jedinica promotrenog obilježja, oznake modaliteta te izvoru podataka.

4. Statistička analiza i interpretacija rezultata provedene analize

Statistička analiza mora imati metode za provođenje analiza bilo kojeg procesa .Njom dobivamo uvid u strukturu procesa u određenom vremenu i prostoru ,te u njihove međusobne veze. Njihov predmet nisu samostalni članovi skupa, nego njihova obilježja koja ukazuju na moguće sličnosti ili razlike. Obilježja se javljaju u oblicima na koja se vežu određene i različite frekvencije kao brojevni izraz nekog oblika u već promatranom statističkom skupu .

Statistički skup ima tri definicije :

- prostornu
- vremensku
- pojmovnu

Prostorna definicija statističkog skupa određuje kojem prostoru treba pripadati promatrana jedinica da bi ju se moglo uključiti u neki statistički skup.

Vremenska definicija statističkog skupa odnosi se na vremensko razdoblje kojim su obuhvaćene jedinice statističkog skupa.

Pojmovna definicija statističkog skupa dokazuje pripadnost skupu pazeći na na pojmovno određenje svih jedinica.

Ukupan iznos frekvencija isti je kao opseg statističkog skupa. Obilježja možemo podijeliti na kvantitativna i kvalitativna. Kvantitativna su ona statistička obilježja koja mjerimo pomoću omjerne skale. Kvalitativna su ona statistička obilježja kod kojih se svojstvo jedinice izražava nebrojčano.

2.2. Odabrani statistički testovi

Vremenski niz je skup poredanih vrijednosti prema vremenskom slijedu kojim se mogu pratiti promjene nekih pojava. Veličine {Yt}, t =1,2,3,4,5...,koje su sastavni dio niza nazivamo frekvencijama. Podaci koji su sastavni dio tog niza zovu se članovi niza frekvencije.

Vremenski niz pomaže da se prati dinamika promjena nekih pojava. U vremenskom nizu imamo podatke koji se većinom odnose na već završene vremenske periode ,a smisao svega je utvrđivanje nekih zakona u razvoju pojave koja se oblikuje za daljnje korištenje u budućnosti

Postoje dvije vrste vremenskog niza:

1. intervalni vremenski niz
2. trenutačni vremenski niz

Intervalni vremenski niz je niz u kojem veličinu pojave mjerimo u vremenskom intervalu.
Trenutačni niz je niz u kojem se mjerenje vrši u momentu vremena.

Razlikuju se dvije vrste vremenskih nizova s obzirom na vremensku definiciju. Ako se veličina pojave mjeri u vremenskom intervalu, kažemo da se radi o intervalnom vremenskom

nizu. Ukoliko se mjerenje ili promatranje vrši u trenutku vremena, kažemo da se radi o trenutačnome vremenskom nizu.[7]

Pojave čije kretanje ima oblik vremenskog niza možemo podijeliti na:

- trend komponenta
- sezonska komponenta
- ciklička komponenta
- slučajna komponenta

Trend komponenta ima određenu hipotezu da vrijednost promotrenog niza ima dugogodišnju težnju pada ili rasta u odnosu na vrijeme.

Sezonska komponenta ima hipotezu stalnog kretanja kroz jednu godinu i da se ponavlja u svakoj od narednih godina.

Ciklička komponenta temelji se na hipotezi koja kaže da je vrijeme stalnog kretanja vrijednosti pojava znatno duže od jedne godine.

Slučajna komponenta ima neredovit učinak, U njoj se utjecaji javljaju s nepredvidljivim djelovanjima u određenom vremenskom prostoru.

Grafički prikaz trebao bi omogućiti prikazati vrijednost kretanja kroz vrijeme na jednostavniji način. Sastoji se od naslova, oznake na ordinati i apscisi, te kazala ako se prikazuje više vremenskih nizova. U vremenskom nizu vrijeme se prikazuje na apscisi, a ordinata nosi vrijednosti Yt. Imamo površinske i linijske grafikone kojima se prikazuju intervalni vremenski nizovi. U linijskom grafikonu vrijednosti pojave se nanose u sredini vremenskog intervala, a u površinskom grafikonu stupci malo stoje na os apscisi, iste su im baze, visina jednaka vrijednosti niza za pojedini ciklus.

Dinamiku vremenskog niza možemo promatrati preko apsolutnih i relativnih pokazatelja.[8]

[7] Rozga, A. (2003): Statistika za ekonomiste. Ekonomski fakultet u Splitu, Split, str. 270
[8] Rozga, A.: op. cit., str. 272-273

Relativni brojeve dijelimo na

- relativni brojeve proporcije
- relativni brojevi koordinacije
- indekse

Relativni brojevi proporcije prikazuju vezu djela i cjeline. Pomoću njih je lakša analiza rasporeda prema modalitetima, a mogu se izražavati u postocima i promilima. Relativni brojevi koji prikazuju vezu apsolutnih frekvencija prema opsegu naziva se relativna frekvencija .

Relativnim brojevima koordinacije se vrijednost frekvencija statističkog niza uspoređuje s frekvencijom nekog drugog statističkog niza tako oboje imaju neovisnost i predstavljaju pojave .

Indeksi su relativni pokazatelji dinamike ,njima uspoređujemo stanje pojava u drukčijem vremenskom ciklusu, trenutku ili lokaciji .

Postoje dvije skupine:

- skupni indeksi
- individualni indeksi

Individualni indeksi se koriste za uspoređivanje stanja određene pojave u nejednakim vremenskim ciklusima. Dijelimo ih na verižne indekse i bazne indekse.

Verižni indeksi pokazuju postotak promjene vrijednosti pojave u jednom ciklusu u odnosu na drugi.

Verižni indeksi se izračunavaju preko sljedećeg izraza:

$$V_t = \frac{Y_t}{Y_{t-1}} * 100, t = 2.3 \ldots . n$$

Kao što je prikazano formulom, verižni indeksi računaju se na način da se stavljaju u odnos vrijednosti pojave tekućeg razdoblja i vrijednosti pojave iz prethodnog razdoblja, te se množi sa 100. Kako se uzima u obzir prethodno razdoblje, prvi verižni indeks nije moguće izračunati.

Za interpretaciju i objašnjenje verižnih indeksa koristi se sljedeća formula, te se prikazuju kao postotak (stop promjene):

$$St = Vt - 100$$

Grafički prikaz verižnih indeksa je poseban. Radi se u pravokutnom sustavu, apscisa pomjerena do 100 na osi ordinata .Za sve nove vremenske periode ucrtava se linijski grafikon kojem ishodište bude u prijašnjem ciklusu. To se radi da bi se mogle očitati promjene u odnosu s prethodnog na sljedeće razdoblje.

Bazni indeksi jesu indeksi koji se računaju na način da se stavljaju u odnos vrijednosti pojave tekućeg razdoblja i vrijednosti pojave odabranog baznog razdoblja, te prikazuju postotak promjene vrijednosti pojave u tekućem razdoblju u odnosu na bazno razdoblje. Formula za računanje baznih indeksa je sljedeća:

$$I_t = \frac{Y_t}{Y_b} * 100$$

Kao i kod verižnih indeksa, za objašnjenje baznih indeksa koristi se stopa promjene:

$$S_t^* = I_t - 100$$

Grafički prikaz je običan i nekompliciran linijski grafikon ,ima pravokutan sustav na kojem su naznačena razdoblja i sve druge oznake koje zahtjeva statistički grafikon.

Korelacija može biti pozitivna ili negativna, te pokazuje međuovisnost slučajnih varijabli. Pozitivna je kada jedna varijabla raste, a druga ju prati i suprotno. Negativna korelacija predstavlja kad rast jedne varijable prati pad druge varijable.[9]

Jedna od najznačajnijih mjera linearne korelacije jest Pearsonov koeficijent linearne korelacije, koji se računa na sljedeći način:

$$r = \frac{\sum_{i=1}^{n} x_i y_i - n\overline{xy}}{\sqrt{\sum x_i^2 - nx^{-2}} * \sqrt{\sum_{i=1}^{n} y_i^2 - ny^{-2}}}$$

U skladu s veličinom koeficijenta korelacije može se zaključiti smjer i intenzitet linearne korelacije među promatranim varijablama:[10]

r=-1; r=1 funkcionalna negativna/pozitivna veza

$-1 < r \leq -0{,}8$; $0{,}8 \leq r < 1$ jaka negativna/pozitivna veza

$-0{,}8 < r \leq -0{,}5$; $0{,}5 \leq r < 0{,}8$ srednje jaka negativna/pozitivna veza

$-0{,}5 < r < 0$; $0 < r < 0{,}5$ slaba negativna/ pozitivna veza

r=0 nema korelacije

[9] Rozga, A.:, str. 183 - 184.
[10] Pivac, S.:, str. 224.

Zadatak **regresijske analize** je pronalazak analitičko matematičkih podataka u obliku veze između ovisne i neovisne varijable.

U slučaju postojanja samo jedne ovisne ili regresand i samo jedne neovisne ili regresorske varijable kaže se da je to jednostavni, jednostruki ili jednodimenzionalni regresijski model.55.[11]

Regresijska analiza se može postaviti na slijedeći način:[12]

1. Potpuno, precizno i koncizno definiranje predmeta i ciljeva istraživanja, te postavljanje osnovnih pretpostavki.
2. Crtanje dijagrama rasipanja, izbor modela i definiranje varijabli.
3. Odabir konkretnog regresijskog modela, njegova specifikacija i pretpostavke. (Na primjer, linearni model: $Y = \beta 0 + \beta 1X + e$).
4. Statistička analiza modela: ocjena parametara i pokazatelja reprezentativnosti modela. U ovoj fazi regresijske analize ocjenjuju se parametri konkretnog izabranog regresijskog modela, te se računaju odgovarajući pokazatelji reprezentativnosti modela, koji ukazuju na to da li model zadovoljava statističke kriterije.
5. Testiranje hipoteza o modelu i statističko teorijskih pretpostavki.
6. DA - ako su ispunjene pretpostavke, vrši se sinteza rezultata i donose se sudovi o predmetu istraživanja.
   NE -ako nisu ispunjene pretpostavke: vrši se modifikacija modela i vraća se na korak 2), tj. na izbor novog modela i definiranje varijabli.

Prema navedenom može se zaključiti da regresijska analiza služi za traženje i ocjenjivanje onih parametra funkcije koji će nabolje opisati vezu varijabli X i Y. Pri regresijskoj analizi postoje dvije hipoteze:

H0 – nulta hipoteza (svi parametri regresijske analize = 0)
H1 – alternativna hipoteza (parametri regresijske analize nisu jednaki 0)

[11] Pivac, S. (2010.): Statističke metode, Ekonomski fakultet u Splitu, Split, str 253.
[12] Pivac, S.: op. cit., str. 254

Također, analiza se provodi i usporedbom empirijske i tablične vrijednosti F-testa. Da bi se dobila empirijska vrijednost F-testa, potrebno je izračunati ANOVA tablicu, odnosno tablicu varijance, što će se detaljnije prikazati u praktičnom dijelu rada.

3. DEVIZNI TEČAJ

3.1. Pojam i formiranje deviznog tečaja

„Devizni tečaj pokazuje koliko je domaćeg novca potrebno dati za jednu ili sto jedinica stranog novca. Devizni tečaj se formira pod utjecajem ponude i potražnje na deviznom tržištu, a formirat će se u onoj točki gdje se ponuda i potražnja stranih sredstava plaćanja nalazi u ravnoteži. Uvjeti ponude i potražnje određeni su suficitom ili deficitom platne bilance zemlje.“[13]

Prema navedenoj definiciji, može se zaključiti da devizni tečaj predstavlja relaciju između izraženih cijena domaćeg i stranog novca, odnosno da je riječ o cijenama domaće valute izražene u stranoj valuti i obrnuto. U svakom gospodarstvu, utjecaj deviznog tečaja od velike je važnosti. Razlog za to vidi se kroz utjecaj deviznog tečaja na sve makroekonomske faktore gospodarstva, gdje će npr. porast tečaja utjecati na skuplji uvoz.

„Devizni tečaj predstavlja razmjenu efektivnog novca (valute) jedne zemlje za efektivni novac (valutu) druge zemlje. Devizni tečaj, s druge strane, predstavlja razmjenu potraživanja u valuti zemlje A, za potraživanje u valuti zemlje B, jer je po definiciji deviza potraživanje u stranoj valuti. Deviza, dakle, nije materijalni novac već pravo potraživanja prema inozemstvu koje kao takvo postoji na bankarskim računima u inozemstvu. Deviza praktično u međunarodnim plaćanjima predstavlja svojevrsni međunarodni depozitni novac koji se kao nematerijalan vodi na računima korespondentnih banaka zemlje A i zemlje B. Budući da je efektivni novac moguće (i lakše) krivotvoriti, u praksi banke posebno iskazuju visinu tečaja za efektivu (gotov novac) koji je u pravilu niži od tečaja za devize, i to zbog rizika krivotvorenja novca i manipulativnih troškova prijenosa novca iz zemlje u zemlju.“[14]

[13] Ćurak, M., Jakovčević, D. (2007): Osiguranje i rizici., RRiF plus, Zagreb, str. 110.- 115
[14] Pcrišin, I., Šokman, A., Lovrinović, I. (2001): Monetama politika Fakultet ekonomije i turizma „Dr. Mijo Mirković“, Pula, str 336.

Osnova za formiranje tečaja valuta jest odnos ponude i potražnje na deviznom tržištu. Devizno tržište je dio ukupnog tržišta na kojemu se prema određenim pravilima trguje devizama, odnosno razmjenjuju se nacionalne valute po deviznom tečaju formiranom na osnovi njihove ponude i potražnje.[15] Dakle, devizno tržište ima nekoliko funkcija kao što je trgovanje ili razmjenjivanje devizama, transferiranje kupovnih moći i financijskih sredstava, te ima kreditnu funkciju.

Ponuda i potražnja na deviznom tržištu predstavlja objektivne čimbenike koji utječu na formiranje deviza. Osim navedenog, razlikuju se i subjektivni čimbenici koji isto tako imaju utjecaja na formiranje deviznog tečaja. Tako su subjektivni čimbenici sljedeći:[16]

- Osnovni trend tržišta,
- Vremenska neusklađenost plaćanja za uvoz i naplata izvoza,
- Pregovaračka vještina subjekata u vanjskoj trgovini,
- Tržišna očekivanja u pogledu terminskih tečajeva,
- Špekulantska kretanja kapitala zbog političke, privredne i društvene situacije,
- Promjena uvjeta na novčarskom i financijskom tržištu,
- Fiskalne i monetarne mjere koje vlasti donose radi kontrole tečajeva.

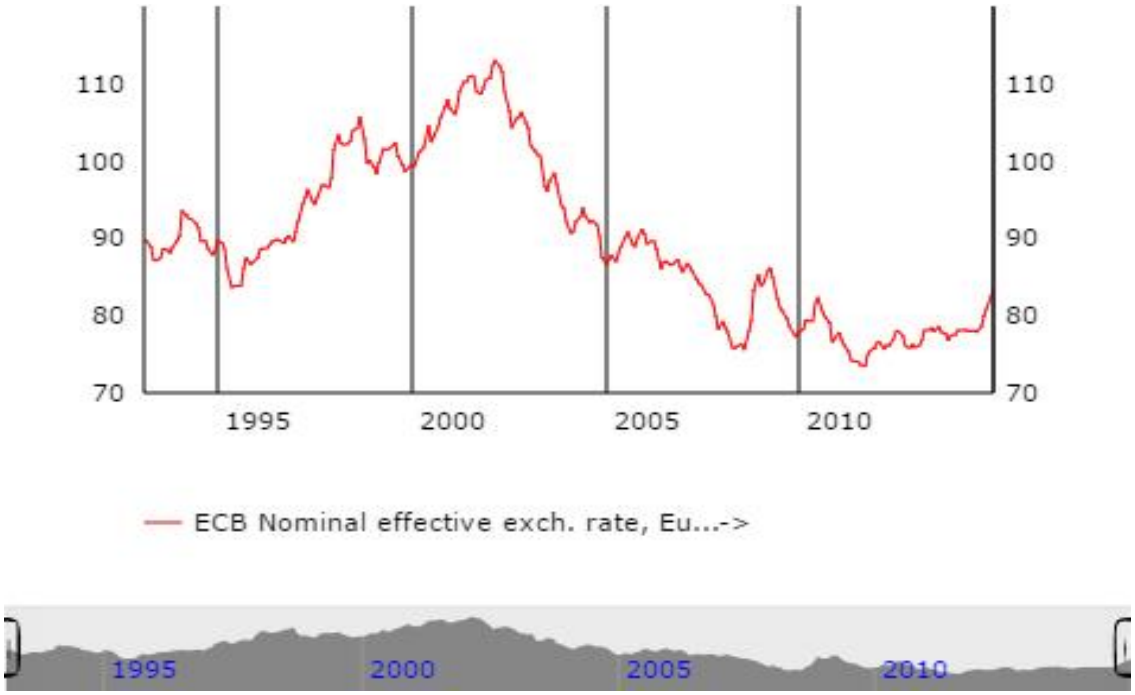
Kod povećanja ili smanjenja valuta u odnosu na druge valute bitno je istaknuti dva pojma. Prvi je aprecijacija, što znači da se dogodilo povećanje jedne valute u odnosu na drugu valutu. Nasuprot navedenome, pojam deprecijacija označava pad vrijednosti jedne valute nasuprot druge valute.

Bitno je napomenuti da će povećanje deviznog tečaja, u slučaju ulaganja kune, utjecati sa manje koristi na to ulaganje, dok će smanjenje ili pad deviznog tečaja povećati korisnost ulaganja kune.

3.2. Kretanje tečaja Eura

[15] http://limun.hr/main.aspx?id=12393&Page=2; pristupljeno [16.9.2016.]
[16] Babić, M., Babić, A. (2008): Međunarodna ekonomija. MATE, Zagreb, str.252

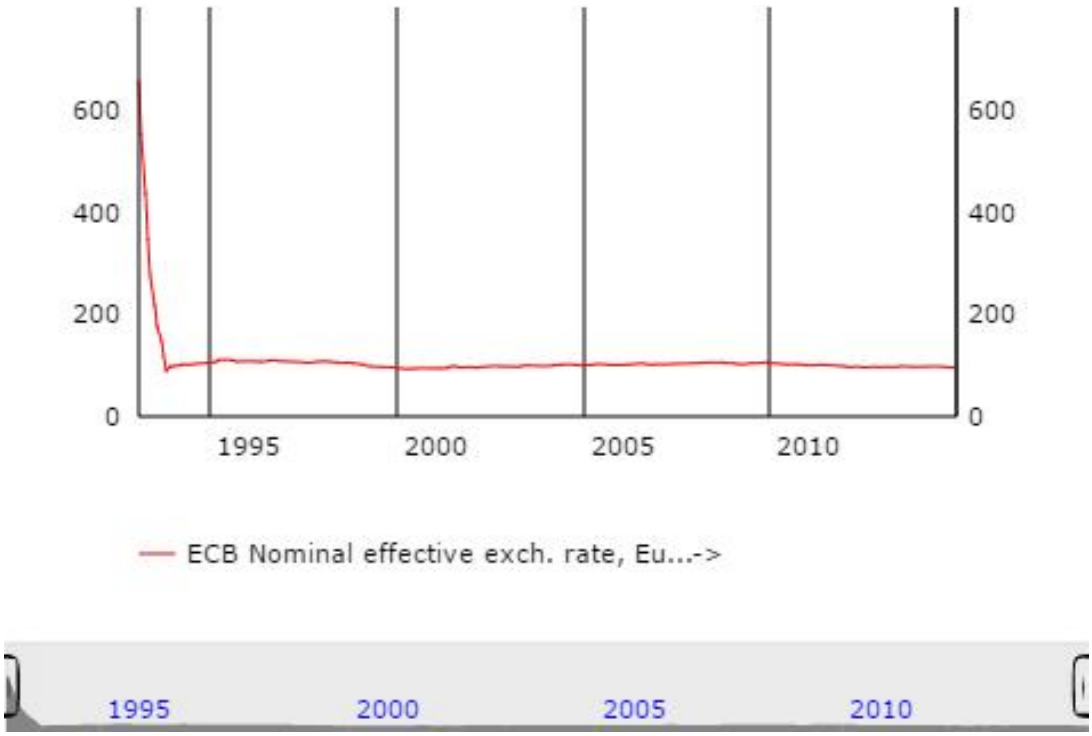
Euro je jedinstvena valuta u EU koja se počela koristi 1.siječnja 1999. godine, kada je u EU bilo 12 zemalja. Danas je taj broj veći, te se u EU nalazi 19 zemalja. U nastavku rada prikazat će se kretanje valuta kune, švicarske franke, britanske funte te američkog dolara u odnosu na Euro. Navedeno će se prikazati preko odgovarajućih grafikona.



Grafikon 1. Kretanje efektivnog deviznog tečaja između Eura i američkog dolara (USD)

Izvor: http://sdw.ecb.europa.eu/quickview.do?SERIES_KEY=120.EXR.M.E1.USD.EN00.A; pristupljeno [17.9.2016.]

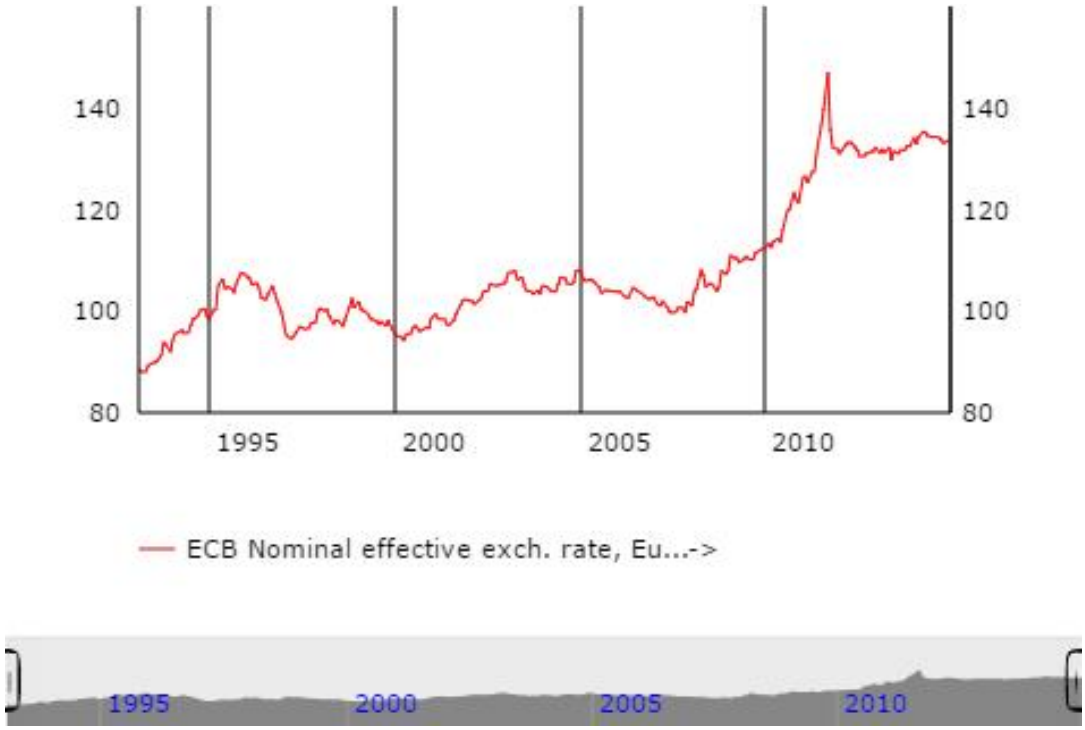
Kao što je prikazano u Grafikonu 1., u 1995. godini vrijednost 100 dolara bila je oko 87 Eura, što je znatno manje u odnosu na prethodna razdoblja. Nakon 1995. godine, vrijednost 100 USD konstantno raste te se penje na vrijednost od 111 Eura, što je najveća zabilježena vrijednost u periodu koji se promatra. Nakon 2002. godine, vrijednost naglo pada do 2007. godine. Najniža vrijednost 100 USD bila je na polovici 2011. godine kada je iznosila oko 74 Eura.



Grafikon 2. Grafikon 1. Kretanje efektivnog deviznog tečaja između Eura i hrvatske kune (HRK)

Izvor: http://sdw.ecb.europa.eu/quickview.do?SERIES_KEY=120.EXR.M.E1.USD.EN00.A; pristupljeno [17.9.2016.]

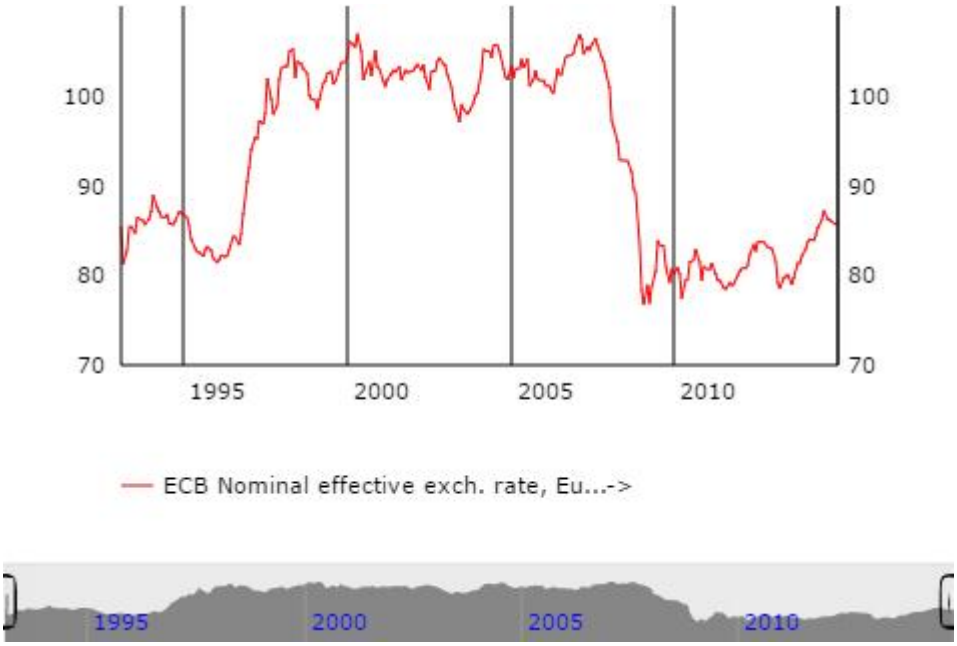
Prema Grafikonu 2., vrijednost 100 jedinica kune prije 1995. godine bila je najniža te je iznosila oko 88 eura. Nakon 1995. godine vrijednost 100 jedinica kune zadržala je sličnu vrijednost sve do danas, te se kreće oko 97 eura.



Grafikon 3. Grafikon 1. Kretanje efektivnog deviznog tečaja između Eura i švicarske franke (CHF)

Izvor: http://sdw.ecb.europa.eu/quickview.do?SERIES_KEY=120.EXR.M.E1.USD.EN00.A; pristupljeno [17.9.2016.]

Kao što je prikazano Grafikonom 3., vrijednost 100 jedinica franka u 1995. godini bila je oko 105 Eura, nakon čega slijedi manji pad do 2003. godine. U 2003. godini vrijednost 100 franaka bila je oko 105 eura, te se je zadržala do 2010. godine nakon čega slijedi veliki rast. Najveća vrijednost tečaja eura bila je 2011. godine kada je iznosila 146 eura u odnosu na 100 jedinica franka.



Grafikon 4. Grafikon 1. Kretanje efektivnog deviznog tečaja između Eura i britanske funte (GBP)

Izvor: http://sdw.ecb.europa.eu/quickview.do?SERIES_KEY=120.EXR.M.E1.USD.EN00.A; pristupljeno [17.9.2016.]

Prema prikazanom grafikonu, tijekom 1995. godine tečaj eura u odnosu na britansku funtu bio je oko 82 eura, nakon čega slijedi veliki rast vrijednosti eura. U 2000. godini tečaj eura u odnosu na britansku funtu ima najveću najveću vrijednost te iznosi oko 106 eura. Navedena vrijednost zadržala se sve do 2008. godine, nakon čega ta vrijednost naglo pada (deprecijacija tečaja eura). Najniža vrijednost eura bila je 2009. te je iznosila 76 eura. Također, u istoj godini dolazi do porasta tečaja (aprecijacija), koji se nastavlja sve do danas, kada vrijednost 100 franaka iznosi oko 85 eura.

4. STATISTIČKA ANALIZA TEČAJA EURA OD 1995. DO 2015.

U nastavku rada prikazat će se rezultati analize kretanja tečaja Eura od 1995. godine do 2015. godine u odnosu na švicarsku franku, kunu, britansku funtu te američki dolar.

4.1. Jednostavni linearni trend

GBP/EURO

Tablica 1. Jednostavni linearni trend GBP/EURO

Regression Summary for Dependent Variable: GBP/Euro (Tecaj Euro)
R= ,44740290 R2= ,20016936 Adjusted R2= ,19680872
F(1,238)=59,563 p<,00000 Std.Error of estimate: 9,0951

N=240	Beta	Std.Err. - of Beta	B	Std.Err. - of B	t(238)	p-level
Intercept			85,89929	1,170511	73,38613	0,000000
Xt	0,447403	0,057971	0,06540	0,008474	7,71771	0,000000

Izvor: izrada autora

Jednadžba jednostavnog linearnog trenda je: 85,89929 + 0,06540Xt

Konstantni član iznosi 85,89929, te prikazuje da se očekuje tečaj britanske funte prema Euru 85,899929 u početnom razdoblju, odnosno kada je Xt=0.

Parametar uz varijablu vrijeme pokazuje da uz svaki porast vremena za jednu jedinicu (mjesec) dolazi do porasta zavisne varijable za 0,06540.

Koeficijent determinacije govori da je protumačeno 20,01% ukupnog zbroja kvadrata odstupanja zavisne varijable od aritmetičke sredine.

Standardna pogreška iznosi 9,0951, što znači da je prosječno odstupanje od stvarnih vrijednosti Eura od očekivanih vrijednosti Eura 9,0951.

Koeficijent varijacije iznosi 9,71%, što znači da je prosječno odstupanje od regresijskog pravca manje od 30%, te je ocjenjeni trend model reprezentativan.

Empirijski F-omjer je 59,563, što znači da se pri empirijskoj razini signifikantnosti od 5% prihvaća se hipoteza H1 – ocjenjeni trend model je statistički značajan.

HRK/EURO

Tablica 2. Jednostavni linearni trend HRK/EURO

Regression Summary for Dependent Variable: HRK/Euro (Tecaj Euro)
R= ,34418140 R2= ,11846084 Adjusted R2= ,11475689
F(1,238)=31,982 p<,00000 Std.Error of estimate: 4,0963

N=240	Beta	Std.Err. - of Beta	B	Std.Err. - of B	t(238)	p-level
Intercept			98,37248	0,527178	186,6019	0,000000
Xt	0,344181	0,060860	0,02158	0,003817	5,6553	0,000000

Izvor: izrada autora

Jednadžba jednostavnog linearnog trenda je: 98,37248 + 0,02158Xt

Konstantni član iznosi 98,37248, te prikazuje da se očekuje tečaj kune prema Euru 98,37248 u početnom razdoblju, odnosno kada je Xt=0.

Parametar uz varijablu vrijeme pokazuje da uz svaki porast vremena za jednu jedinicu (mjesec) dolazi do porasta zavisne varijable za 0,02158.

Koeficijent determinacije govori da je protumačeno 11,84% ukupnog zbroja kvadrata odstupanja zavisne varijable od aritmetičke sredine.

Standardna pogreška iznosi 4,0963, što znači da je prosječno odstupanje od stvarnih vrijednosti Eura od očekivanih vrijednosti Eura 4,0963.

Koeficijent varijacije iznosi 4,05%, što znači da je prosječno odstupanje od regresijskog pravca manje od 30%, te je ocjenjeni trend model reprezentativan.

Empirijski F-omjer je 31,982, što znači da se pri empirijskoj razini signifikantnosti od 5% prihvaća se hipoteza H1 – ocjenjeni trend model je statistički značajan.

USD/EURO

Tablica 3. Jednostavni linearni trend USD/EURO

Regression Summary for Dependent Variable: USD/Euro (Tecaj Euro)
R= ,55356939 R2= ,30643906 Adjusted R2= ,30352494
F(1,238)=105,16 p<0,0000 Std.Error of estimate: 9,8365

N=240	Beta	Std.Err. - of Beta	B	Std.Err. - of B	t(238)	p-level
Intercept			77,67574	1,265929	61,35870	0,000000
Xt	0,553569	0,053983	0,09398	0,009165	10,25459	0,000000

Izvor: izrada autora

Jednadžba jednostavnog linearnog trenda je: 77,67574 + 0,09398Xt

Konstantni član iznosi 77,67574, te prikazuje da se očekuje tečaj američkog dolara prema Euru 77,67574 u početnom razdoblju, odnosno kada je Xt=0.

Parametar uz varijablu vrijeme pokazuje da uz svaki porast vremena za jednu jedinicu (mjesec) dolazi do porasta zavisne varijable za 0,09398.

Koeficijent determinacije govori da je protumačeno 30,64% ukupnog zbroja kvadrata odstupanja zavisne varijable od aritmetičke sredine.

Standardna pogreška iznosi 9,8365, što znači da je prosječno odstupanje od stvarnih vrijednosti Eura od očekivanih vrijednosti Eura 9,8365.

Koeficijent varijacije iznosi 11,06%, što znači da je prosječno odstupanje od regresijskog pravca manje od 30%, te je ocjenjeni trend model reprezentativan.

Empirijski F-omjer je 105,16, što znači da se pri empirijskoj razini signifikantnosti od 5% prihvaća se hipoteza H1 – ocjenjeni trend model je statistički značajan.

CHF/EURO

Tablica 4. Jednostavni linearni trend CHF/EURO

Regression Summary for Dependent Variable: CHF/Euro (Tecaj Euro)
R= ,80545963 R2= ,64876521 Adjusted R2= ,64728944
F(1,238)=439,61 p<0,0000 Std.Error of estimate: 7,5699

N=240	Beta	Std.Err. - of Beta	B	Std.Err. - of B	t(238)	p-level
Intercept			125,7284	0,974230	129,0540	0,00
Xt	-0,805460	0,038416	-0,1479	0,007053	-20,9669	0,00

Izvor: izrada autora

Jednadžba jednostavnog linearnog trenda je: 125,7284 – 0,1479Xt

Konstantni član iznosi 125,7284, te prikazuje da se očekuje tečaj švicarskog franka prema Euru 125,7284 u početnom razdoblju, odnosno kada je Xt=0.

Parametar uz varijablu vrijeme pokazuje da uz svaki porast vremena za jednu jedinicu (mjesec) dolazi do pada zavisne varijable za 0,1479.

Koeficijent determinacije govori da je protumačeno 64,87% ukupnog zbroja kvadrata odstupanja zavisne varijable od aritmetičke sredine.

Standardna pogreška iznosi 7,5699, što znači da je prosječno odstupanje od stvarnih vrijednosti Eura od očekivanih vrijednosti Eura 7,5699.

Koeficijent varijacije iznosi 7%, što znači da je prosječno odstupanje od regresijskog pravca manje od 30%, te je ocjenjeni trend model reprezentativan.

Empirijski F-omjer je 439,61, što znači da se pri empirijskoj razini signifikantnosti od 5% prihvaća se hipoteza H1 – ocjenjeni trend model je statistički značajan.

4.2. Logaritamska parabola

GBP/EURO

Tablica 5. Logaritamska parabola GBP/EURO

Regression Summary for Dependent Variable: log gbp/euro (Tecaj Euro)
R= ,78558828 R2= ,61714895 Adjusted R2= ,61391814
F(2,237)=191,02 p<0,0000 Std.Error of estimate: ,02985

N=240	Beta	Std.Err. - of Beta	B	Std.Err. - of B	t(237)	p-level
Intercept			1,863792	0,005733	325,1163	0,000000
Xt	2,92886	0,160146	0,002027	0,000111	18,2887	0,000000
Xt^2	-2,55794	0,160146	-0,000007	0,000000	-15,9726	0,000000

Izvor: izrada autora

Jednadžba logaritamskog polinoma je: log Yt = 1,863792 + 0,002027Xt – 0,000007Xt^2

Jednadžba trenda originalnog oblika je: $\hat{Y}_t$=73,07889973*1,004678249^{Xt}*0,999983882 X_t^2

$\hat{\beta}_0$ = 73,07889973 što znači da je tečaj britanske funte 73,07889973 na početku promatranog razdoblja (vrijeme je nula).

$\hat{\beta}_1$ = 1,004678249 što znači da tečaj ima prosječni rast za 0,04678249% na mjesečnoj bazi.

$\hat{\beta}_2$ = 0,999983882 što znači da tečaj u prosjeku pada za 0,0016118% na mjesečnoj bazi.

Da li je procijenjeni trend značajan ili ne, ocijenit će se preko F- testa:

H_0:...log$\hat{\beta}_j$=0 $\forall$j (model nije značajan)

H_1:... $\exists$ log$\hat{\beta}_j \neq 0$ (model je značajan)

Empirijski F-omjer je 191,02, što znači da se pri empirijskoj razini signifikantnosti od 5% prihvaća se hipoteza H1 – ocjenjeni trend model je statistički značajan.

HRK/EURO

Tablica 6. Logaritamska parabola HRK/EURO

Regression Summary for Dependent Variable: log hrk/euro (Tecaj Euro)
R= ,40198661 R2= ,16159324 Adjusted R2= ,15451807
F(2,237)=22,840 p<,00000 Std.Error of estimate: ,01714

N=240	Beta	Std.Err. - of Beta	B	Std.Err. - of B	t(237)	p-level
Intercept			2,002564	0,003293	608,2032	0,000000
Xt	-0,542565	0,236989	-0,000146	0,000064	-2,2894	0,022935
Xt^2	0,903421	0,236989	0,000001	0,000000	3,8121	0,000176

Izvor: izrada autora

Jednadžba logaritamskog polinoma je: log Yt = 2,002564 – 0,000146Xt + 0,000001t^2

Jednadžba trenda originalnog oblika je: $\hat{Y}_t$=100,592129*0,9996638791^{Xt}*1,000002303$^{X_t^2}$

$\hat{\beta}_0$ = 100,592129 što znači da je tečaj britanske funte 100,592129 na početku promatranog razdoblja (vrijeme je nula).

$\hat{\beta}_1$ = 0,9996638791 što znači da tečaj ima prosječni pad za 0,03361209% na mjesečnoj bazi.

$\hat{\beta}_2$ = 0,999983882 što znači da tečaj u prosjeku pada za 0,999983882 na mjesečnoj bazi.

Da li je procijenjeni trend značajan ili ne, ocijenit će se preko F- testa:

H_0:...log$\hat{\beta}_j$=0 $\forall$j (model nije značajan)

H_1:... $\exists$ log$\hat{\beta}_j$≠0 (model je značajan)

Empirijski F-omjer je 22,840, što znači da se pri empirijskoj razini signifikantnosti od 5% prihvaća se hipoteza H1 – ocjenjeni trend model je statistički značajan.

CHF/EURO

Tablica 7. Logaritamska parabola CHF/EURO

	Regression Summary for Dependent Variable: log chf/euro (Tecaj Euro) R= ,91666608 R2= ,84027670 Adjusted R2= ,83892882 F(2,237)=623,41 p<0,0000 Std.Error of estimate: ,01940					
N=240	**Beta**	**Std.Err. - of Beta**	**B**	**Std.Err. - of B**	**t(237)**	**p-level**
Intercept			2,143476	0,003726	575,1995	0,000000
Xt	-2,43749	0,103439	-0,001697	0,000072	-23,5645	0,000000
Xt^2	1,67680	0,103439	0,000005	0,000000	16,2105	0,000000

Izvor: izrada autora

Jednadžba logaritamskog polinoma je: log Yt = 2,143476 – 0,001697Xt + 0,000005Xt^2

Jednadžba trenda originalnog oblika je: $\hat{Y}_t$=139,1476897*0,9961001374^{Xt}*1,000011513$^{X_t^2}$

$\hat{\beta}_0$ = 139,1476897 što znači da je tečaj švicarskog franka 139,1476897 na početku promatranog razdoblja (vrijeme je nula).

$\hat{\beta}_1$ = 0,996100137 što znači da tečaj ima prosječni pad za 0,3899626 % na mjesečnoj bazi.

$\hat{\beta}_2$ = 1,000011513 što znači da tečaj u prosjeku raste za 0,0011513% na mjesečnoj bazi.

Da li je procijenjeni trend značajan ili ne, ocijenit će se preko F- testa:

H_0:...log$\hat{\beta}_j$=0 $\forall$j (model nije značajan)

H_1:... $\exists$ log$\hat{\beta}_j \neq 0$ (model je značajan)

Empirijski F-omjer je 632,41, što znači da se pri empirijskoj razini signifikantnosti od 5% prihvaća se hipoteza H1 – ocjenjeni trend model je statistički značajan.

USD/EURO

Tablica 8. Logaritamska parabola USD/EURO

Regression Summary for Dependent Variable: log usd/euro (Tecaj Euro)
R= ,50085361 R2= ,25085434 Adjusted R2= ,24453244
F(2,237)=39,680 p<,00000 Std.Error of estimate: ,06945

N=240	Beta	Std.Err. - of Beta	B	Std.Err. - of B	t(237)	p-level
Intercept			1,832501	0,013338	137,3931	0,000000
Xt	1,71940	0,224018	0,001979	0,000258	7,6753	0,000000
Xt^2	-1,41012	0,224018	-0,000007	0,000001	-6,2947	0,000000

Izvor: izrada autora

Jednadžba logaritamskog polinoma je: log Yt = 1,832501 + 0,001979Xt – 0,000007Xt^2

Jednadžba trenda originalnog oblika je: $\hat{Y}_t$=67,99876107*1,004567214^{Xt}*0,999983882$^{Xt^2}$.

$\hat{\beta}_0$ = 67,99876107 što znači da je tečaj američkog dolara 67,99876107 na početku promatranog razdoblja (vrijeme je nula).

$\hat{\beta}_1$ = 1,004567124 što znači da tečaj ima prosječni rast za 0,4567124% na mjesečnoj bazi.

$\hat{\beta}_2$ = 0,999983882 što znači da tečaj u prosjeku pada za 0,0016118% na mjesečnoj bazi.

Da li je procijenjeni trend značajan ili ne, ocijenit će se preko F- testa:

H_0:...log$\hat{\beta}_j$=0 $\forall$j (model nije značajan)

H_1:...$\exists$ log$\hat{\beta}_j$≠0 (model je značajan)

Empirijski F-omjer je 39,680, što znači da se pri empirijskoj razini signifikantnosti od 5% prihvaća se hipoteza H1 – ocjenjeni trend model je statistički značajan.

4.3. Sezonske varijacije

U ovom dijelu rada analizirat će se klasična dekompozicija vremenskog niza koji se odnosi na tečaj britanske funte, kune, švicarske franke i američkog dolara. Navedena analiza provest će se multiplikativnom metodom.

HRK

Tablica 9. Dekompozicija vremenskog niza tečaja HRK multiplikativnom metodom

Case	Seasonal Decomposition: Multipl. season (12); Centered means (Tečaj Eura) HRK/EURO						
	HRK/EURO	Moving Averages	Ratios	**Seasonal Factors**	Adjusted Series	Smoothed Trend-c.	Irreg. Compon.
1	95,6648			99,5592	96,0883	95,7767	1,003254
2	95,6025			99,8225	95,7725	95,8880	0,998796
3	95,7827			99,9786	95,8032	96,1107	0,996800
4	96,5426			100,0151	96,5280	96,4393	1,000920
5	97,0201			100,1269	96,8971	96,8144	1,000855
6	97,5153			100,3282	97,1963	97,1436	1,000543
7	98,1243	97,1313	101,0224	100,7578	97,3863	97,3748	1,000118
8	98,1739	97,2710	100,9283	100,5793	97,6084	97,5650	1,000445
9	98,0066	97,3970	100,6259	100,3062	97,7074	97,6921	1,000157
10	97,6343	97,4909	100,1471	99,7527	97,8763	97,7985	1,000796
11	97,2005	97,5668	99,6246	99,4369	97,7510	97,8583	0,998903
12	97,3820	97,6424	99,7333	99,3366	98,0323	97,8497	1,001866
13	97,5158	97,6889	99,8228	99,5592	97,9475	97,7264	1,002262
14	97,1046	97,6603	99,4310	99,8225	97,2773	97,5189	0,997522
15	97,3042	97,5583	99,7396	99,9786	97,3250	97,4425	0,998794
16	97,2759	97,4637	99,8073	100,0151	97,2612	97,5110	0,997439
17	98,1071	97,4305	100,6944	100,1269	97,9828	97,7123	1,002768
18	98,2437	97,4209	100,8446	100,3282	97,9223	97,6753	1,002530
19	98,5114	97,3839	101,1578	100,7578	97,7705	97,3954	1,003852
20	97,1019	97,3276	99,7681	100,5793	96,5426	96,9713	0,995580
21	96,6291	97,2764	99,3345	100,3062	96,3341	96,8522	0,994651
22	96,7421	97,2804	99,4467	99,7527	96,9819	97,0615	0,999180
23	97,2970	97,2270	100,0720	99,4369	97,8480	97,4036	1,004563
24	97,0529	97,0663	99,9862	99,3366	97,7010	97,4486	1,002590
25	96,9588	96,8906	100,0704	99,5592	97,3880	97,2520	1,001399
26	96,3092	96,7849	99,5085	99,8225	96,4805	97,0547	0,994084
27	96,8721	96,8159	100,0580	99,9786	96,8928	96,9757	0,999145
28	97,8025	96,8885	100,9434	100,0151	97,7878	96,8739	1,009433

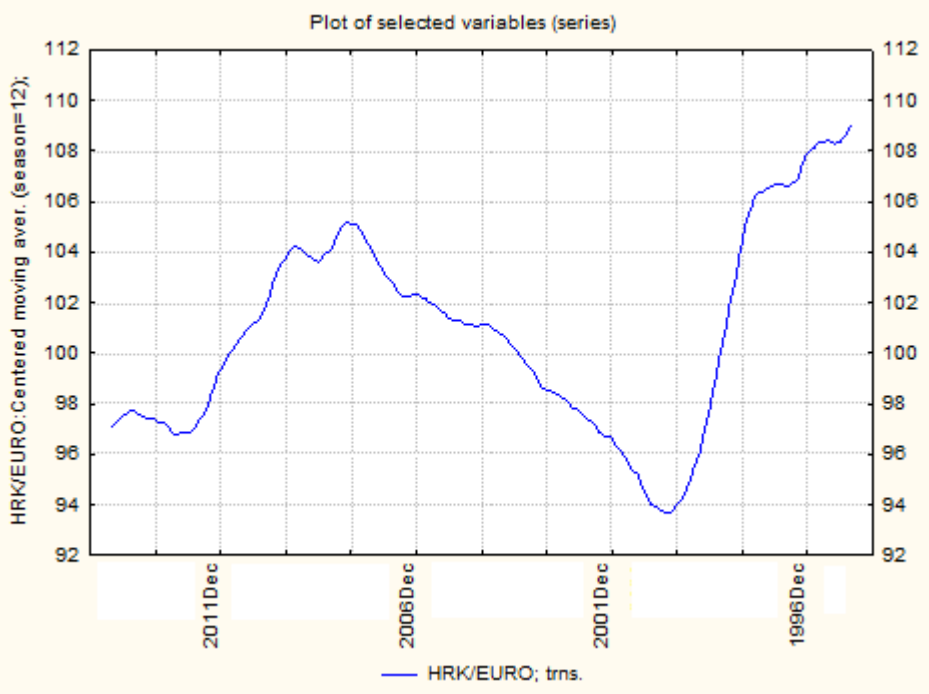
Izvor: izrada autora

Kao što to prikazuje Tablica 9., prvi centrirani pomični prosjek iznosi:

CM1 = (1/2*95,6648 + 95,6025 + 95,7827 + 96,5426 + 97,0201 + 97,5153 + 98,1243 + 98,1739 + 98,0066 + 97,6343 + 97,2005 + 97,3820 + ½*97,5158) / 12 = 97,1313

Prema prikazanome, centrirani dvanaesteročlani pomični prosjek je je trinaestočlani ponderirani pomični prosjek koji ima pondere 1/24 i 1/12. Ponder 1/24 odnosi se na prvi i zadnji član, dok se ponder 1/12 odnosi na ostale članove.

Prikazanom formulom računaju se i ostali centrirani dvanaesteročlani pomični prosjeci.

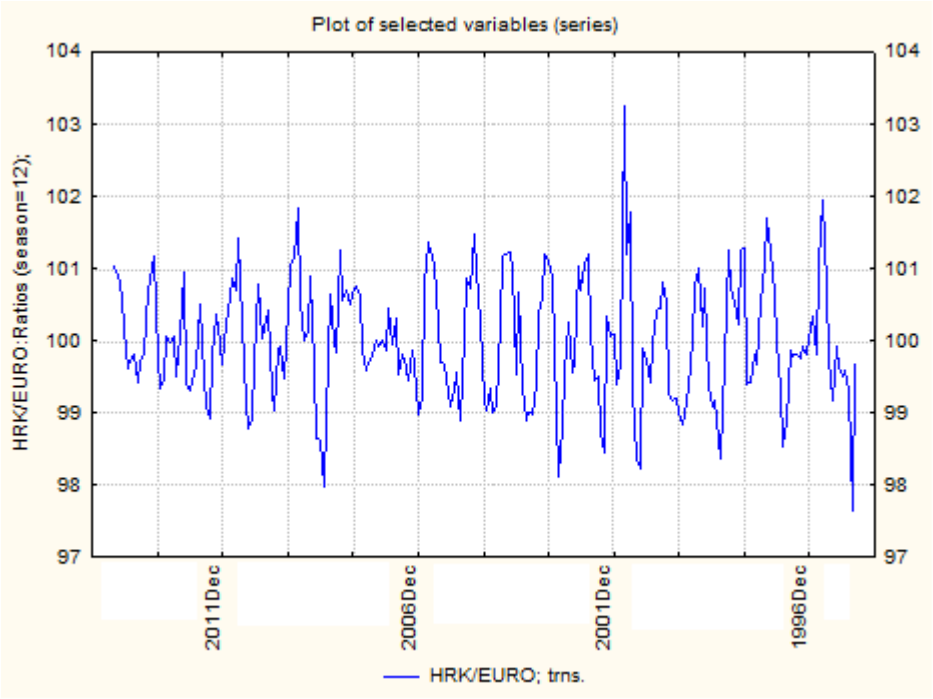


Grafikon 5. Centrirani pomični prosjek tečaja HRK

Izvor: izrada autora

Prve procjene sezonskih indeksa jednake su omjerima onih originalnih vrijednosti vremenskog nize i odgovarajućim centriranim pomičnim prosjecima:

I1s = (98,1243 / 97,1313)*100 = 101,0224
I2s = (98,1739 / 97,2710)*100 = 100,9283
I3s = (98,066 / 97,3970)*100 = 101,0224



Grafikon 6. Prve procjene sezonskih indeksa tečaja HRK

Izvor: izrada autora

U nastavku rada prikazat će se izračuni prosječnih sezonskih indeksa. Bitno je napomenuti da da vrijednosti prosječnih sezonskih indeksa trebaju biti jednaki kao u Tablici 9., no međutim u ovom slučaju postoje male razlike koje se mogu prepisati zaokruživanju decimala. Također su provedene i potrebne korekcije. Ukupna vrijednost prosječnih sezonskih indeksa je 1200.

Tablica 10. Prosječni sezonski indeksi, korekcije i stope promjene tečaja HRK

Mjesec	Vrijednosti	Korekcija I.		Stopa promjene	Korekcija II.		Stopa promjene
siječanj	99,5592	99,6821	99,6813	-0,3187	99,6230	99,62253	-0,37747
veljača	99,8225	99,7907	99,7899	-0,2101	99,7335	99,73302	-0,26698
ožujak	99,9786	99,9186	99,9177	-0,0823	99,8199	99,81942	-0,18058
travanja	100,0151	99,9057	99,9049	-0,0951	99,8634	99,86285	-0,13715
svibanj	100,1269	100,0711	100,0702	0,0702	100,0947	100,09420	0,09420
lipanj	100,3282	100,4114	100,4106	0,4106	100,4461	100,44558	0,44558
srpanj	100,7578	100,6887	100,6879	0,6879	100,7604	100,75987	0,75987
kolovoz	100,5793	100,4123	100,4114	0,4114	100,4645	100,46400	0,46400
rujan	100,3062	100,4438	100,4430	0,4430	100,5194	100,51891	0,51891
listopad	99,7527	99,8672	99,8664	-0,1336	99,8804	99,87992	-0,12008
studeni	99,4369	99,4745	99,4737	-0,5263	99,5051	99,50463	-0,49537
prosinac	99,3366	99,3438	99,3429	-0,6571	99,2956	99,295078	-0,70492
	1200,0000	1200,0099	1200,0000	0,0000	1200,0062	1200,0000	
		0,99999175			0,999994793		

Izvor: izrada autora

Objašnjenje:

Npr.: siječanj (-0,3187) – u siječnju se zbog sezonskih utjecaja očekuje pad tečaja HRK za 0,3178%.

Npr.: rujan (0,51891) – u rujnu se zbog sezonskih utjecaja očekuje porast tečaja HRK za 0,5189%.

Iz prikazane tablice je uočljivo kako je rast tečaja HRK zabilježen tijekom ljetnih mjeseci, dok je pad tečaja HRK izraženiji u prosincu i siječnju.

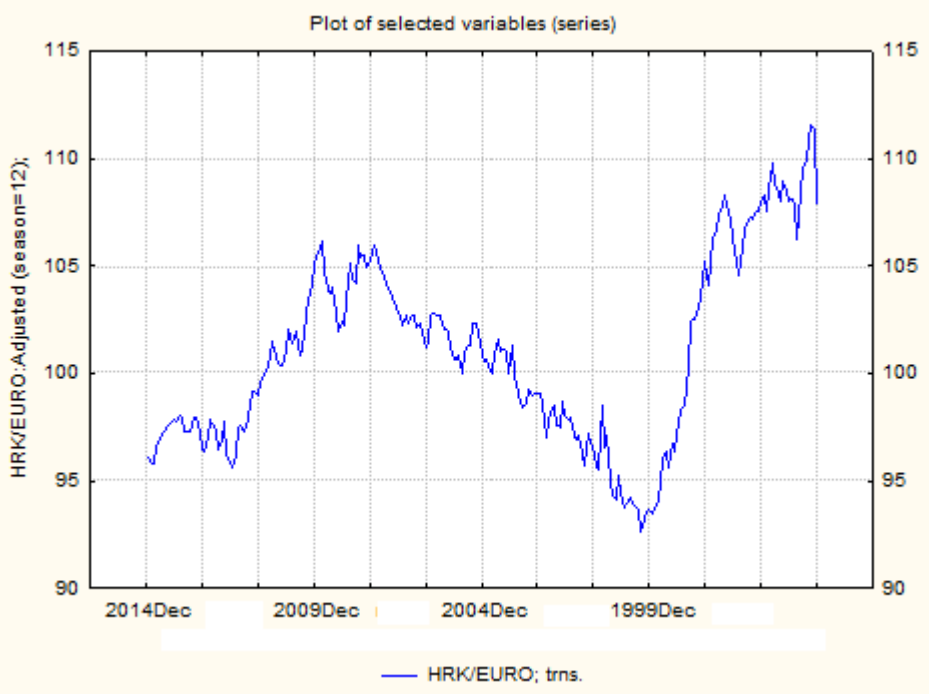
Nadalje, u radu će se prikazati i desezonirane vrijednosti vremenskog niza koje prikazuju vrijednosti tečaja bez sezonskih utjecaja. riječ je o vrijednostima koje se računaju na način da se originalne vrijednosti vremenskog niza podjele sa konačnim procjenama sezonskih indeksa, te se pomože sa 100:

y_1*=95,6648/99,5592*100 = 96,0883 što znači da bi bez sezonskog utjecaja tečaj bi iznosio 96,0883.

y_2*=95,6025/99,8225*100 = 95,7725 što znači da bi bez sezonskog utjecaja tečaj bi iznosio 95,7725.

y_3*=95,7827/99,9786*100 = 95,8032 što znači da bi bez sezonskog utjecaja tečaj bi iznosio 95,8032.

Ostale vrijednosti izračunavaju se na isti način.



Grafikon 7. Desezonirane vrijednosti tečaja HRK

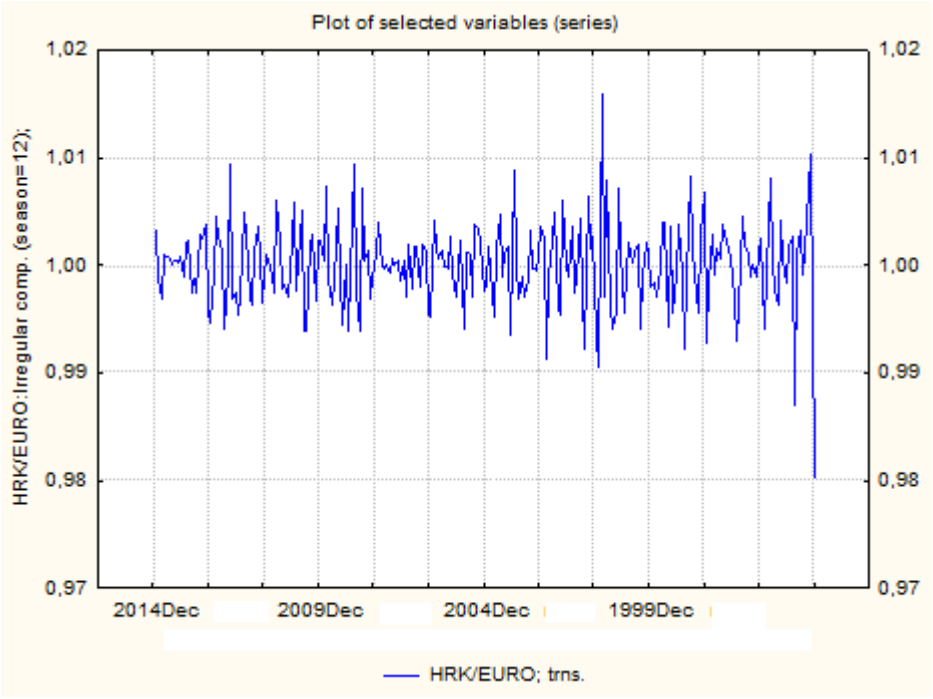
Izvor: izrada autora

Kao posljednji korak izračuna koriste se faktori rezidualnih odstupanja (iregularna komponenta). ovaj faktor, odnosno indeks dobije se tako da se desezonirane vrijednosti podjele sa vrijednostima na koje nema sezonskih utjecaja.

$I_{1,e}$=96,6883/95,7767*100=100,325

$I_{2,e}$=95,7725/95,8880*100=99,87

Na isti način računaju se i ostale vrijednosti.

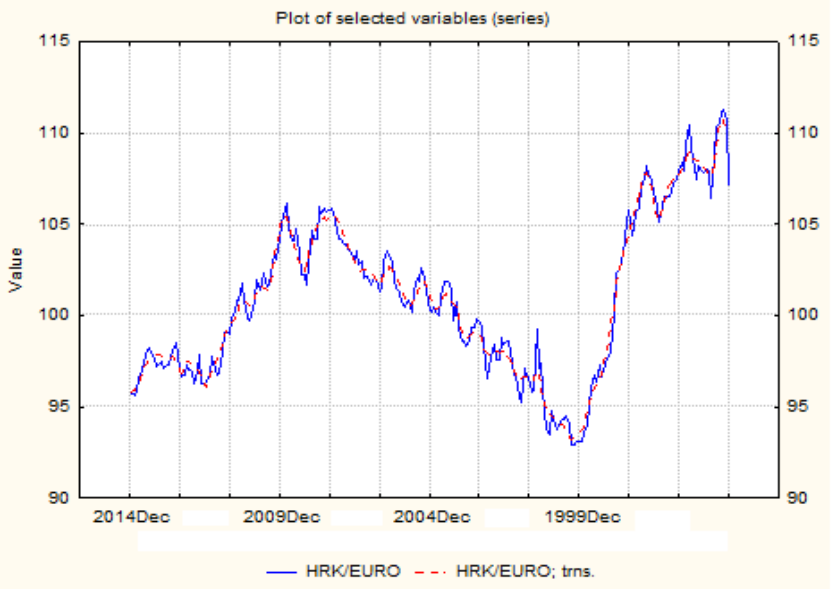


Grafikon 8. Iregularna komponenta tečaja HRK

Izvor; izrada autora

Vrijednosti promatranog vremenskog niza za prva dva opažanja imaju mogućnost dekomponirati se na sljedeći način:

95,6648 = 95,7767*(99,5592/100)*(103,254/100)



Grafikon 9. Usporedba originalnog vremenskog niza tečaja eura i izglađene trend-cikličke vrijednosti

Izvor: izrada autora

GBP

Tablica 11. Dekompozicija vremenskog niza tečaja GBP multiplikativnom metodom

Case	Seasonal Decomposition: Multipl. season (12); Centered means (Tečaj Eura) GBP/EURO						
	GBP/EURO	Moving Averages	Ratios	Seasonal Factors	Adjusted Series	Smoothed Trend-c.	Irreg. Compon.
1	85,9190			100,0051	85,9146	85,8782	1,000424
2	85,6577			99,8040	85,8260	85,8784	0,999390
3	85,9512			100,0660	85,8945	85,8787	1,000184
4	86,1245			100,3524	85,8221	86,0195	0,997705
5	86,2648			100,2917	86,0139	86,2149	0,997669
6	87,1920			100,1443	87,0664	86,3176	1,008675
7	86,1471	85,2680	101,0309	99,9145	86,2208	86,0590	1,001880
8	85,2864	84,9976	100,3398	99,9051	85,3674	85,5016	0,998430
9	84,5208	84,6618	99,8335	99,4512	84,9872	84,8656	1,001433
10	83,8655	84,2049	99,5969	99,9232	83,9300	84,3116	0,995474
11	84,0208	83,6363	100,4597	100,0091	84,0131	83,9013	1,001333
12	83,7579	83,0382	100,8667	100,1335	83,6463	83,4523	1,002325
13	82,9367	82,4793	100,5545	100,0051	82,9325	82,8967	1,000431
14	82,1490	81,9831	100,2023	99,8040	82,3104	82,0630	1,003015
15	81,4002	81,5033	99,8735	100,0660	81,3465	81,0285	1,003925
16	79,7113	81,0603	98,3358	100,3524	79,4314	80,0951	0,991714
17	79,0306	80,7623	97,8559	100,2917	78,8008	79,6053	0,989894
18	80,0719	80,6277	99,3106	100,1443	79,9565	79,6104	1,004347
19	79,8544	80,6001	99,0748	99,9145	79,9227	79,6698	1,003174
20	79,6703	80,6458	98,7904	99,9051	79,7459	79,5939	1,001911
21	78,6208	80,7825	97,3240	99,4512	79,0547	79,6178	0,992927
22	79,1349	81,0451	97,6431	99,9232	79,1958	80,1627	0,987938
23	81,5975	81,4066	100,2345	100,0091	81,5901	81,2195	1,004563
24	82,9521	81,7121	101,5175	100,1335	82,8415	82,2574	1,007101
25	83,0802	81,9712	101,3529	100,0051	83,0760	82,9672	1,001311
26	83,1011	82,2302	101,0591	99,8040	83,2643	83,2805	0,999806
27	83,7301	82,4455	101,5581	100,0660	83,6749	83,4332	1,002897
28	83,6824	82,6202	101,2857	100,3524	83,3886	83,3716	1,000203

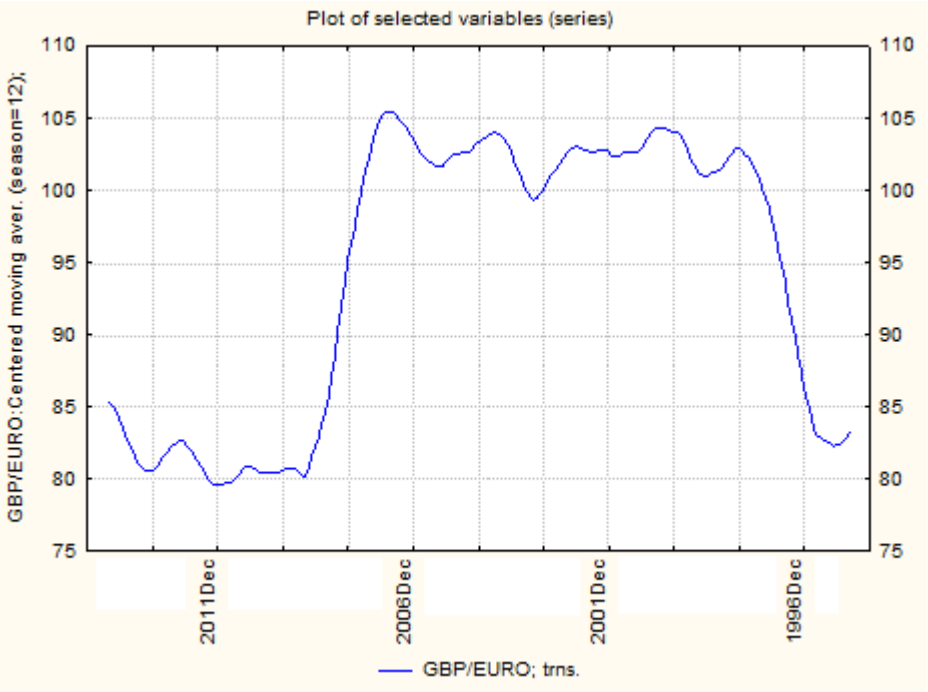
Izvor: izrada autora

Kao što to prikazuje Tablica 11., prvi centrirani pomični prosjek iznosi:

CM1 = (1/2*85,9190 + 85,6577 + 85,9512 + 86,1245 + 86,2648 + 87,7920 + 86,1471 + 85, 2864 + 84,5208 + 83,8655 + 84,0208 + 83,7579 + 1/2*82,9367) / 12 = 85,2680

Prema prikazanome, centrirani dvanaesteročlani pomični prosjek je je trinaestočlani ponderirani pomični prosjek koji ima pondere 1/24 i 1/12. Ponder 1/24 odnosi se na prvi i zadnji član, dok se ponder 1/12 odnosi na ostale članove.

Prikazanom formulom računaju se i ostali centrirani dvanaesteročlani pomični prosjeci.



Grafikon 10. Centrirani pomični prosjek tečaja GBP

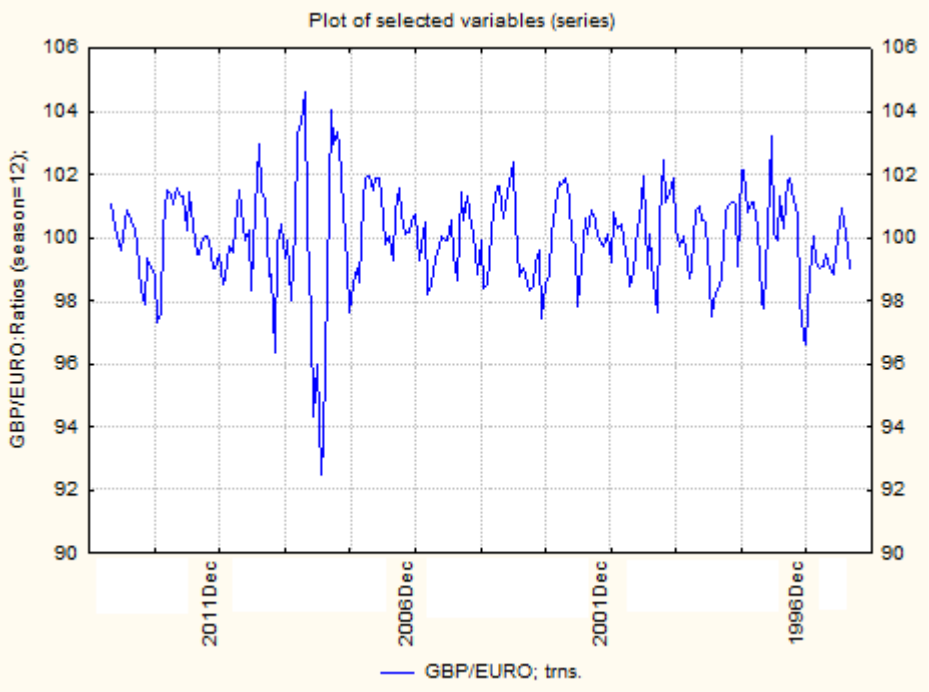
Izvor: izrada autora

Prve procjene sezonskih indeksa jednake su omjerima onih originalnih vrijednosti vremenskog nize i odgovarajućim centriranim pomičnim prosjecima:

I1s = (86,1471 / 85,2680)*100 = 101,0309

I1s = (85,2864 / 84,9976)*100 = 100,3398

I1s = (84,5208 / 84,6618)*100 = 99,8335



Grafikon 11. Prve procjene sezonskih indeksa tečaja GBP

Izvor: izrada autora

U nastavku rada prikazat će se izračuni prosječnih sezonskih indeksa. Bitno je napomenuti da da vrijednosti prosječnih sezonskih indeksa trebaju biti jednaki kao u Tablici 11., No međutim u ovom slučaju postoje male razlike koje se mogu prepisati zaokruživanju decimala. Također su provedene i potrebne korekcije. Ukupna vrijednost prosječnih sezonskih indeksa je 1200.

Mjesec	Original	Korekcija I.		Stopa promjene	Korekcija II.		Stopa promjene
siječanj	100,0051	100,1228	100,17037	0,17037181	100,120952	100,09927	0,09926922
veljača	99,8040	100,1576	100,20522	0,20522363	99,9860388	99,96438	-0,0356152
ožujak	100,0660	100,5047	100,55250	0,55249832	100,47568	100,45392	0,45391983
travanja	100,3524	100,8346	100,88256	0,88255978	100,836356	100,81452	0,81451809
svibanj	100,2917	100,5064	100,55418	0,55417781	100,460079	100,43832	0,43832256
lipanj	100,1443	100,4868	100,53459	0,53459289	100,344515	100,32278	0,32278346
srpanj	99,9145	99,6908	99,73819	-0,2618076	99,7451712	99,72357	-0,2764306
kolovoz	99,9051	99,3898	99,43707	-0,5629298	99,3820171	99,36049	-0,639506
rujan	99,4512	98,7544	98,80129	-1,1987085	98,9012959	98,87988	-1,1201231
listopad	99,9232	99,7509	99,79834	-0,2016633	99,8645672	99,84294	-0,1570605
studeni	100,0091	99,4988	99,54606	-0,4539403	99,9935976	99,97194	-0,028058
prosinac	100,1335	99,7322	99,77963	-0,2203748	100,14967	100,12798	0,12798016
	1200,0000	1199,4301	1200		1200,2599	1200,0000	
		1,000475172			0,99978343		

Tablica 12. Prosječni sezonski indeksi, korekcije i stope promjene tečaja GBP

Izvor: izrada autora

Objašnjenje:

Npr.: siječanj (0,17037181) – u siječnju se zbog sezonskih utjecaja očekuje rast tečaja GBP za 0,17037181%.

Npr.: rujan (-1,1201231) – u rujnu se zbog sezonskih utjecaja očekuje pad tečaja GBP za 1,1201231%.

Iz prikazane tablice je uočljivo kako je rast tečaja GBP zabilježen tijekom ljetnih mjeseci, dok je pad tečaja GBP izraženiji u prosincu i siječnju.

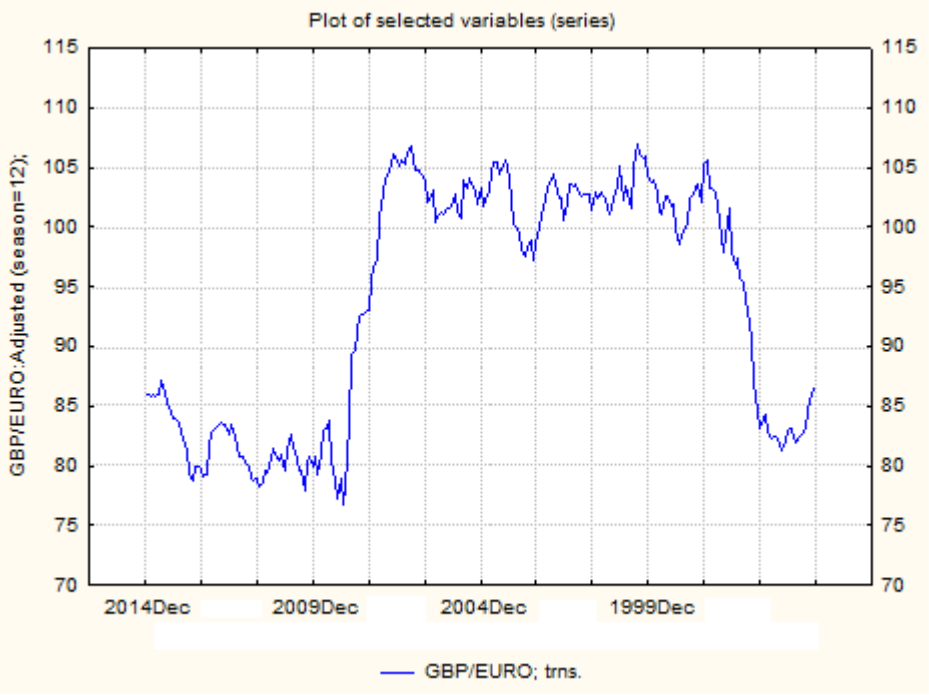
Nadalje, u radu će se prikazati i desezonirane vrijednosti vremenskog niza koje prikazuju vrijednosti tečaja bez sezonskih utjecaja. riječ je o vrijednostima koje se računaju na način da se originalne vrijednosti vremenskog niza podjele sa konačnim procjenama sezonskih indeksa, te se pomože sa 100:

y_1* = 85,9190 / 100,0051*100 = 85,9146 što znači da bi bez sezonskog utjecaja tečaj bi iznosio 85,9146.

y_2* = 85,6577 / 99,8040*100 = 85,8260 što znači da bi bez sezonskog utjecaja tečaj bi iznosio 85,8260.

y_3* = 85,9512 / 100,0660*100 = 85,8945 što znači da bi bez sezonskog utjecaja tečaj bi iznosio 85,8945.

Ostale vrijednosti izračunavaju se na isti način.



Grafikon 12. Desezonirane vrijednosti tečaja GBP

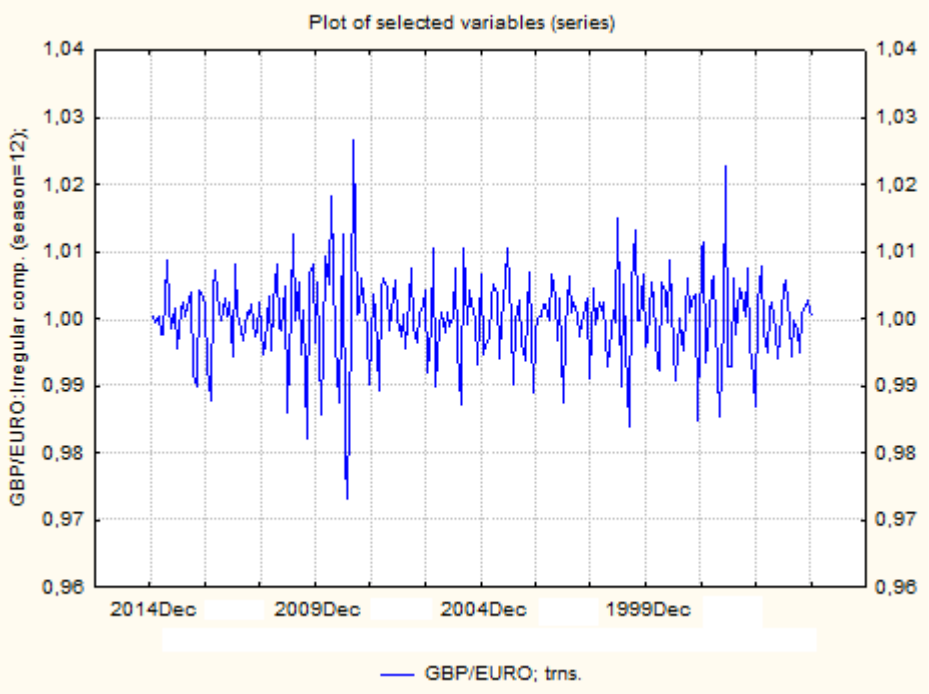
Izvor: izrada autora

Kao posljednji korak izračuna koriste se faktori rezidualnih odstupanja (iregularna komponenta). ovaj faktor, odnosno indeks dobije se tako da se desezonirane vrijednosti podjele sa vrijednostima na koje nema sezonskih utjecaja.

$I_{1,e}$ = 85,9146 / 85,8782*100 = 100,0424

$I_{2,e}$ = 85,8260 / 85,8784*100 = 99,9390

Na isti način računaju se i ostale vrijednosti.

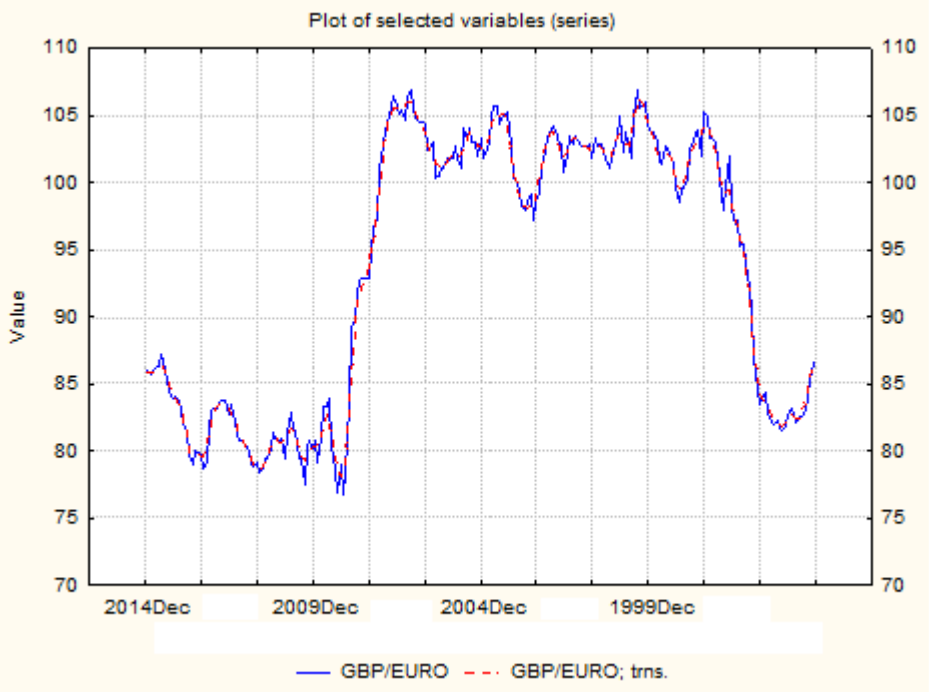


Grafikon 13. Iregularna komponenta tečaja GBP

Izvor; izrada autora

Vrijednosti promatranog vremenskog niza za prva dva opažanja imaju mogućnost dekomponirati se na sljedeći način:

85,9190 = 85,8782*(100,0051/100)*(100,0424/100)



Grafikon 14. Usporedba originalnog vremenskog niza tečaja GBP i izglađene trend-cikličke vrijednosti

Izvor: izrada autora

CHF

Tablica 13. Dekompozicija vremenskog niza tečaja CHF multiplikativnom metodom

Case	Seasonal Decomposition: Multipl. season (12); Centered means (Tečaj Eura) CHF/EURO						
	CHF/EURO	Moving Averages	Ratios	Seasonal Factors	Adjusted Series	Smoothed Trend-c.	Irreg. Compon.
1	133,5957			100,5714	132,8366	132,8861	0,999627
2	133,5970			100,1446	133,4041	133,0940	1,002330
3	133,0100			99,9764	133,0414	133,5098	0,996492
4	133,6163			99,6260	134,1179	134,0111	1,000797
5	134,1545			99,6814	134,5833	134,4740	1,000812
6	134,2391			99,3682	135,0927	134,9060	1,001384
7	134,5062	133,7671	100,5526	99,5944	135,0540	135,0075	1,000345
8	135,3312	133,6451	101,2616	99,8878	135,4832	134,7491	1,005447
9	134,2247	133,5142	100,5322	100,0403	134,1707	134,1619	1,000065
10	132,9966	133,3521	99,7334	100,1852	132,7507	133,4134	0,995033
11	134,0569	133,1299	100,6963	100,4749	133,4233	132,8170	1,004565
12	132,3893	132,8364	99,6634	100,4494	131,7970	132,2365	0,996676
13	132,5703	132,5577	100,0095	100,5714	131,8170	131,9199	0,999220
14	131,6963	132,2883	99,5525	100,1446	131,5061	131,6674	0,998775
15	131,7672	132,0162	99,8114	99,9764	131,7983	131,6707	1,000969
16	130,9693	131,8383	99,3408	99,6260	131,4610	131,5522	0,999307
17	131,4700	131,6797	99,8407	99,6814	131,8902	131,6129	1,002106
18	129,8781	131,5614	98,7205	99,3682	130,7039	131,5698	0,993419
19	132,1794	131,4718	100,5382	99,5944	132,7178	131,7678	1,007209
20	131,1925	131,3914	99,8487	99,8878	131,3398	131,6217	0,997859
21	131,8325	131,3073	100,4000	100,0403	131,7794	131,5547	1,001708
22	131,1199	131,2316	99,9149	100,1852	130,8775	131,2696	0,997013
23	132,1264	131,2168	100,6932	100,4749	131,5020	131,1564	1,002635
24	131,4800	131,3217	100,1206	100,4494	130,8918	130,9490	0,999563
25	131,3296	131,4605	99,9004	100,5714	130,5834	130,7934	0,998394
26	131,0064	131,5665	99,5743	100,1446	130,8172	130,7135	1,000793
27	130,4400	131,6249	99,0998	99,9764	130,4708	130,8438	0,997149
28	130,4800	131,6109	99,1407	99,6260	130,9699	131,3132	0,997385

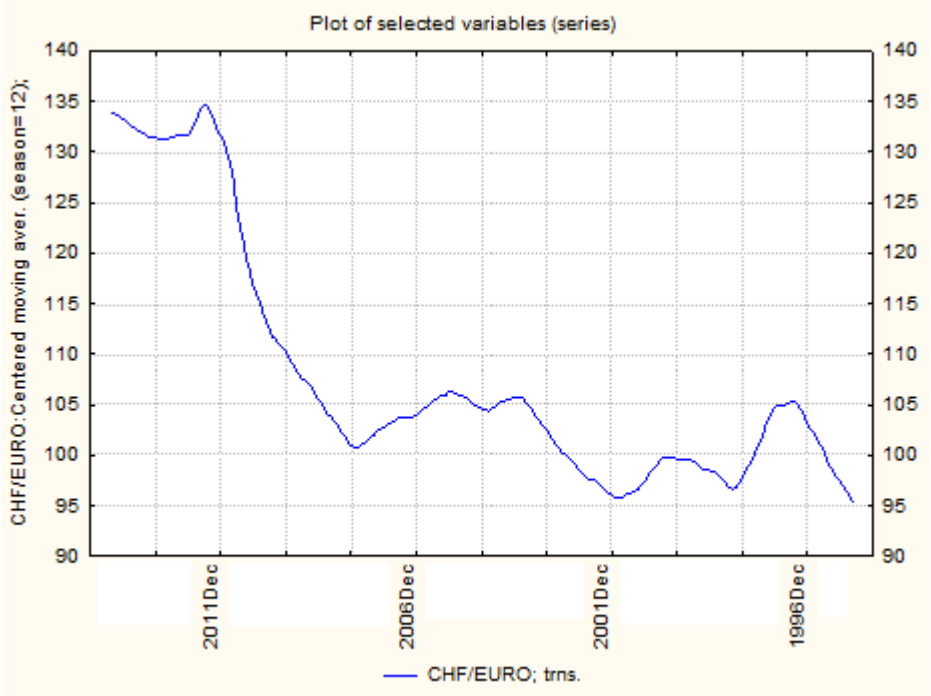
Izvor: izrada autora

Kao što to prikazuje Tablica 13., prvi centrirani pomični prosjek iznosi:

CM1 = (1/2*133,5957 + 133,5970 + 133,0100 + 133,6163 + 134,1545 + 134,5062 + 135,3312 + 134,2247 + 132,9966 + 134,0569 + 132,3893 + 1/2*132,5703) / 12 = 133,7671

Prema prikazanome, centrirani dvanaesteročlani pomični prosjek je je trinaestočlani ponderirani pomični prosjek koji ima pondere 1/24 i 1/12. Ponder 1/24 odnosi se na prvi i zadnji član, dok se ponder 1/12 odnosi na ostale članove.

Prikazanom formulom računaju se i ostali centrirani dvanaesteročlani pomični prosjeci.



Grafikon 15. Centrirani pomični prosjek tečaja CHF

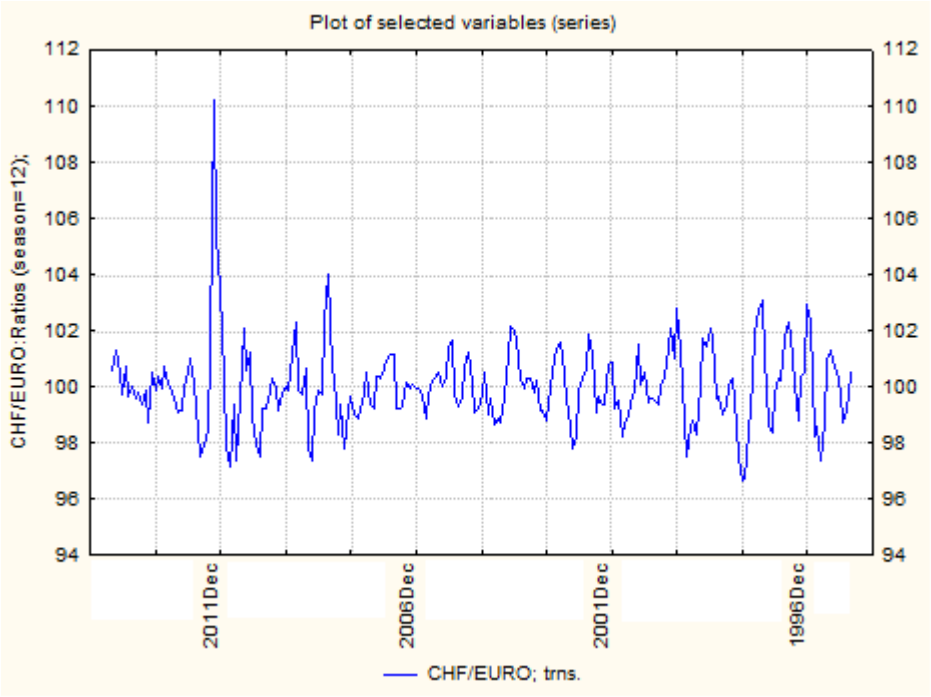
Izvor: izrada autora

Prve procjene sezonskih indeksa jednake su omjerima onih originalnih vrijednosti vremenskog nize i odgovarajućim centriranim pomičnim prosjecima:

I1s = (134,5062 / 133,7671)*100 = 100,5526

I2s = (135,3312 / 133,6451)*100 = 101,2616

I3s = (134,2247 / 133,5142)*100 = 100,5322



Grafikon 16. Prve procjene sezonskih indeksa tečaja CHF

Izvor: izrada autora

U nastavku rada prikazat će se izračuni prosječnih sezonskih indeksa. Bitno je napomenuti da da vrijednosti prosječnih sezonskih indeksa trebaju biti jednaki kao u Tablici 13., No međutim u ovom slučaju postoje male razlike koje se mogu prepisati zaokruživanju decimala. Također su provedene i potrebne korekcije. Ukupna vrijednost prosječnih sezonskih indeksa je 1200.

Tablica 14. Prosječni sezonski indeksi, korekcije i stope promjene tečaja CHF

Mjesec	Original	Korekcija		Stopa promjene
siječanj	100,5714	100,75850	100,7694	0,76937872
veljača	100,1446	100,80370	100,8146	0,814576555
ožujak	99,9764	100,35521	100,366	0,366038678
travanja	99,6260	99,49605	99,50679	-0,493214243
svibanj	99,6814	99,60612	99,61687	-0,383132682
lipanj	99,3682	99,36433	99,37506	-0,624944557
srpanj	99,5944	99,58869	99,59943	-0,400566746
kolovoz	99,8878	99,94185	99,95264	-0,047362282
rujan	100,0403	99,99261	100,0034	0,003399849
listopad	100,1852	99,76155	99,77232	-0,227680404
studeni	100,4749	100,04799	100,0588	0,058787991
prosinac	100,4494	100,15391	100,1647	0,164719124
	1200,0000	1199,87051	1200	
		1,00011		

Izvor: izrada autora

Objašnjenje:

Npr.: siječanj (0,76937872) – u siječnju se zbog sezonskih utjecaja očekuje rast tečaja CHF za 0,76937872%.

Npr.: rujan (0,00339984) – u rujnu se zbog sezonskih utjecaja očekuje rast tečaja CHF za 0,00339984%.

Iz prikazane tablice je uočljivo kako je rast tečaja CHF zabilježen tijekom zimskih mjeseci, dok je pad tečaja CHF izraženiji u travnju, svinju i lipnju.

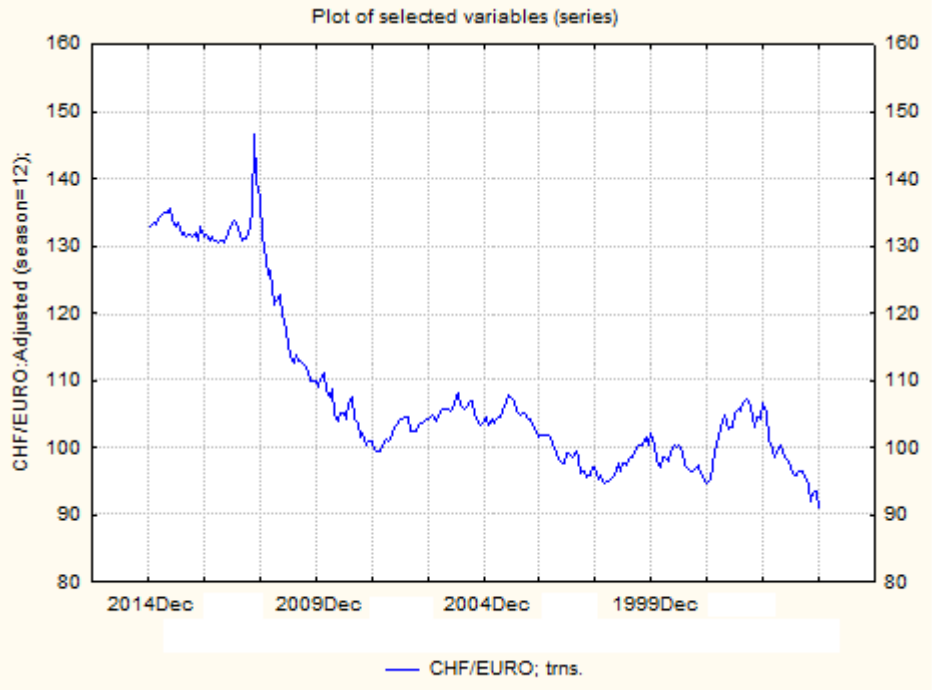
Nadalje, u radu će se prikazati i desezonirane vrijednosti vremenskog niza koje prikazuju vrijednosti tečaja bez sezonskih utjecaja. riječ je o vrijednostima koje se računaju na način da se originalne vrijednosti vremenskog niza podjele sa konačnim procjenama sezonskih indeksa, te se pomože sa 100:

y_1* = 133,5957 / 100,5714*100 = 132,8366 što znači da bi bez sezonskog utjecaja tečaj bi iznosio 132,8366.

y_2* = 133,5970 / 100,1446*100 = 133,4041 što znači da bi bez sezonskog utjecaja tečaj bi iznosio 133,4041.

y_3* = 133,0100 / 99,9764*100 = 133,0414 što znači da bi bez sezonskog utjecaja tečaj bi iznosio 133,0414.

Ostale vrijednosti izračunavaju se na isti način.



Grafikon 17. Desezonirane vrijednosti tečaja CHF

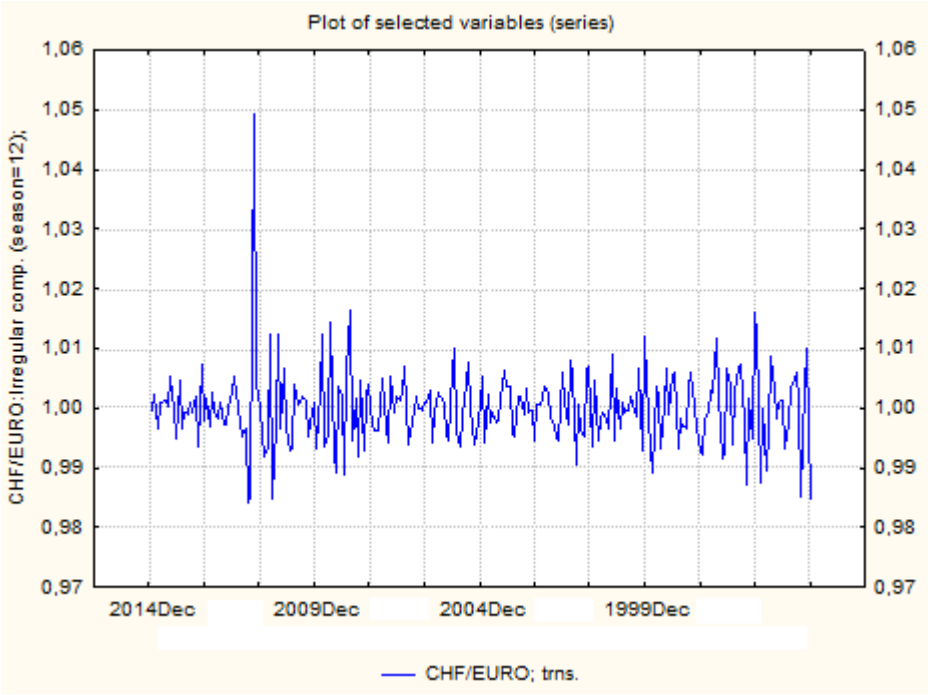
Izvor: izrada autora

Kao posljednji korak izračuna koriste se faktori rezidualnih odstupanja (iregularna komponenta). Ovaj faktor, odnosno indeks dobije se tako da se desezonirane vrijednosti podjele sa vrijednostima na koje nema sezonskih utjecaja.

$I_{1,e}$ = 132,8366 / 132,8861*100 = 99,9627

$I_{2,e}$ = 133,4041 / 133,0940*100 = 100,2330

Na isti način računaju se i ostale vrijednosti.

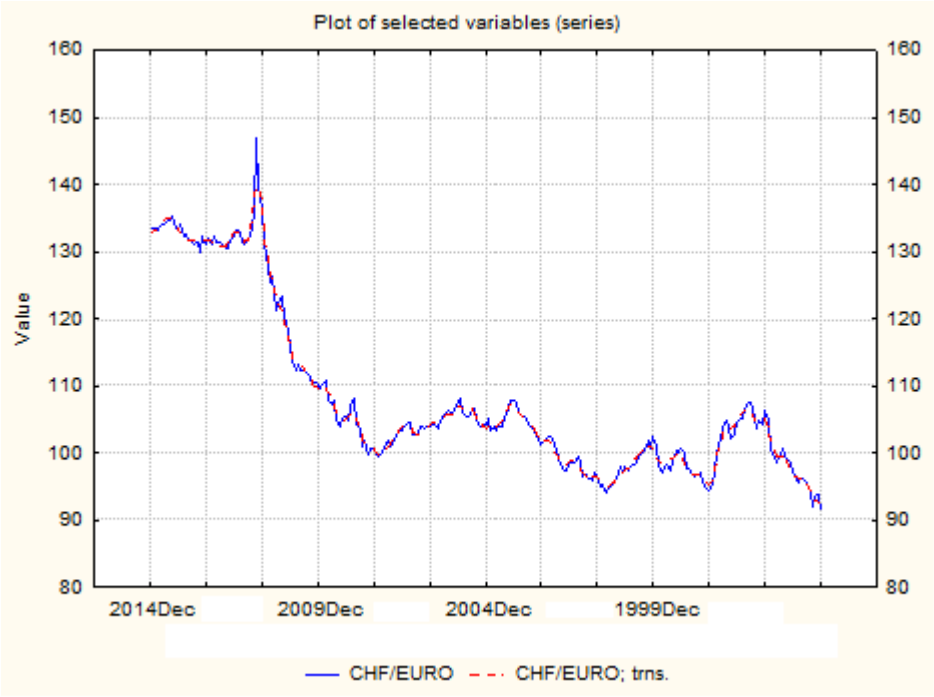


Grafikon 18. Iregularna komponenta tečaja CHF

Izvor: izrada autora

Vrijednosti promatranog vremenskog niza za prva dva opažanja imaju mogućnost dekomponirati se na sljedeći način:

133,5957 = 132,8861*(100,5714/100)*(99,9624/100)



Grafikon 19. Usporedba originalnog vremenskog niza tečaja CHF i izglađene trend-cikličke vrijednosti

Izvor: izrada autora

USD

Tablica 15. Dekompozicija vremenskog niza tečaja USD multiplikativnom metodom

Case	Seasonal Decomposition: Multipl. season (12); Centered means (Tečaj Eura) USD/EURO						
	USD/EURO	Moving Averages	Ratios	Seasonal Factors	Adjusted Series	Smoothed Trend-c.	Irreg. Compon.
1	83,5247			100,2118	83,3482	82,7704	1,006980
2	82,3549			100,1774	82,2090	82,2078	1,000015
3	80,8473			99,7300	81,0662	81,0825	0,999798
4	79,9300			99,7358	80,1417	79,9339	1,002600
5	78,5856			100,1159	78,4946	78,9060	0,994787
6	77,8568			100,2676	77,6490	78,2607	0,992184
7	78,0666	79,0330	98,7772	100,0569	78,0222	78,0524	0,999613
8	77,9335	78,5473	99,2186	99,6288	78,2239	78,0952	1,001648
9	78,0626	78,1810	99,8486	99,8698	78,1644	78,1586	1,000074
10	78,1555	77,9604	100,2502	99,9908	78,1627	78,1269	1,000458
11	78,0477	77,8743	100,2227	99,8833	78,1389	77,9793	1,002048
12	78,0820	77,8771	100,2631	100,3320	77,8236	77,6769	1,001889
13	77,4231	77,8948	99,3944	100,2118	77,2595	77,4125	0,998024
14	76,7978	77,9158	98,5651	100,1774	76,6618	77,3391	0,991242
15	77,6142	77,9245	99,6018	99,7300	77,8243	77,6328	1,002467
16	77,8695	77,8758	99,9919	99,7358	78,0758	77,9151	1,002061
17	78,5783	77,7470	101,0692	100,1159	78,4873	78,1398	1,004448
18	77,9320	77,5758	100,4591	100,2676	77,7240	78,1494	0,994557
19	78,4169	77,4338	101,2696	100,0569	78,3723	78,2252	1,001881
20	78,0864	77,3426	100,9617	99,6288	78,3774	78,1088	1,003438
21	78,1179	77,2316	101,1475	99,8698	78,2198	77,7705	1,005778
22	76,9322	77,1381	99,7330	99,9908	76,9393	77,0848	0,998113
23	76,1801	77,0889	98,8211	99,8833	76,2691	76,4644	0,997447
24	75,8410	77,0647	98,4121	100,3320	75,5900	76,0087	0,994492
25	76,2547	77,0062	99,0241	100,2118	76,0936	75,9105	1,002412
26	75,7775	76,8633	98,5873	100,1774	75,6433	76,0594	0,994529
27	75,9720	76,6981	99,0532	99,7300	76,1777	76,5296	0,995401
28	77,2677	76,5653	100,9174	99,7358	77,4724	77,1061	1,004750

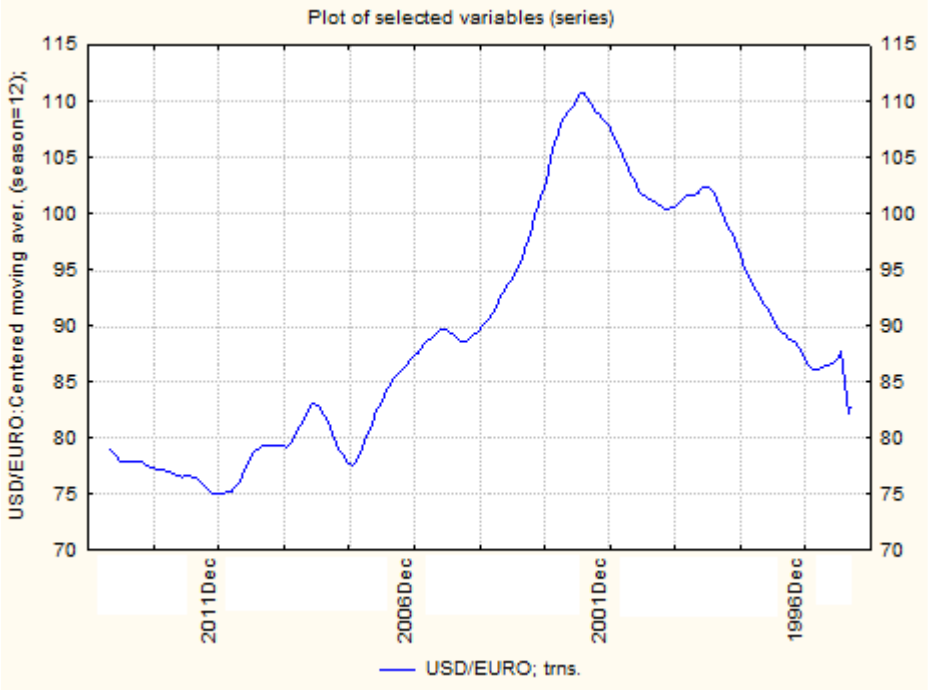
Izvor: izrada autora

Kao što to prikazuje Tablica 15., prvi centrirani pomični prosjek iznosi:

CM1 = (1/2*83,5247 + 82,3549 + 80,8473 + 79,9300 + 78,5856 + 77,8568 + 78,0666 + 77,9335 + 78,0626 + 78,1555 + 78,0477 + 78,0820 + 1/2*77,4231) / 12 = 79,0330

Prema prikazanome, centrirani dvanaesteročlani pomični prosjek je je trinaestočlani ponderirani pomični prosjek koji ima pondere 1/24 i 1/12. Ponder 1/24 odnosi se na prvi i zadnji član, dok se ponder 1/12 odnosi na ostale članove.

Prikazanom formulom računaju se i ostali centrirani dvanaesteročlani pomični prosjeci.



Grafikon 20. Centrirani pomični prosjek tečaja USD

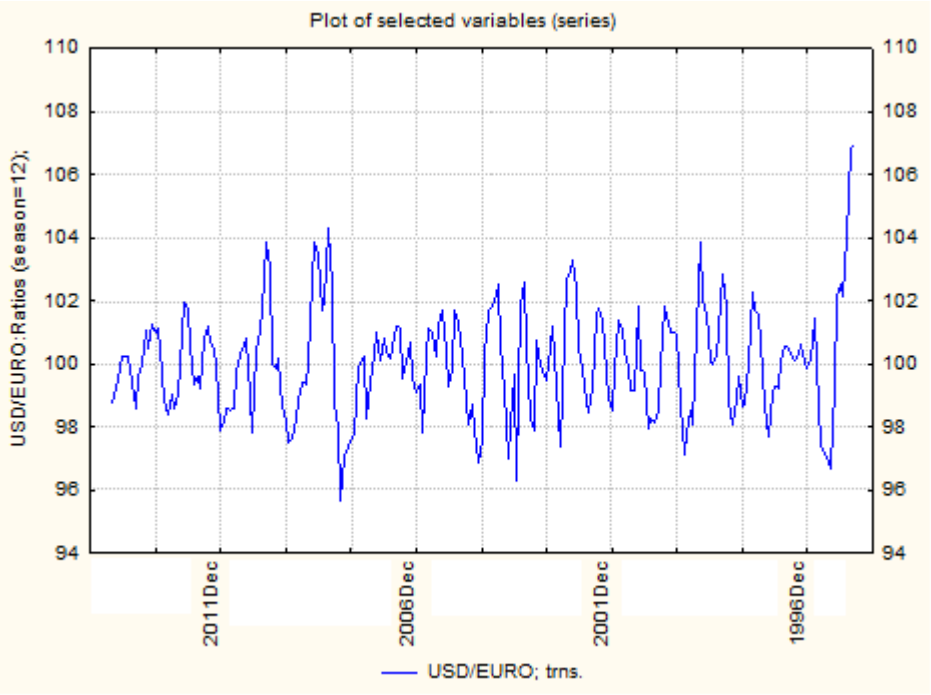
Izvor: izrada autora

Prve procjene sezonskih indeksa jednake su omjerima onih originalnih vrijednosti vremenskog nize i odgovarajućim centriranim pomičnim prosjecima:

I1s = (78,066 / 79,0330)*100 = 98,7772

I2s = (77,9335 / 78,5473)*100 = 99,2186

I3s = (78,0626 / 78,1810)*100 = 99,8486



Grafikon 21. Prve procjene sezonskih indeksa tečaja USD

Izvor: izrada autora

U nastavku rada prikazat će se izračuni prosječnih sezonskih indeksa. Bitno je napomenuti da da vrijednosti prosječnih sezonskih indeksa trebaju biti jednaki kao u Tablici 15., No međutim u ovom slučaju postoje male razlike koje se mogu prepisati zaokruživanju decimala. Također su provedene i potrebne korekcije. Ukupna vrijednost prosječnih sezonskih indeksa je 1200.

Tablica 16. Prosječni sezonski indeksi, korekcije i stope promjene tečaja USD

Mjesec	Original	Korekcija		Stopa promjene
siječanj	100,2118	100,03793	100,0477	0,047676434
veljača	100,1774	99,9840646	99,99381	-0,006193941
ožujak	99,7300	99,8968974	99,90663	-0,093369656
travanja	99,7358	100,132387	100,1421	0,142142827
svibanj	100,1159	100,365926	100,3757	0,375704929
lipanj	100,2676	100,081184	100,0909	0,09093535
srpanj	100,0569	99,976685	99,98643	-0,013574333
kolovoz	99,6288	99,4711256	99,48082	-0,51918294
rujan	99,8698	99,9576376	99,96738	-0,032623573
listopad	99,9908	100,184931	100,1947	0,194692073
studeni	99,8833	99,7428062	99,75252	-0,247475891
prosinac	100,3320	100,051521	100,0613	0,061268721
	1200,0000	1199,8831	1200	
		1,00009743		

Izvor: izrada autora

Objašnjenje:

Npr.: siječanj (0,047676434) – u siječnju se zbog sezonskih utjecaja očekuje rast tečaja USD za 0,047676434%.

Npr.: rujan (-0,032623573) – u rujnu se zbog sezonskih utjecaja očekuje pad tečaja USD za 0,032623573%.

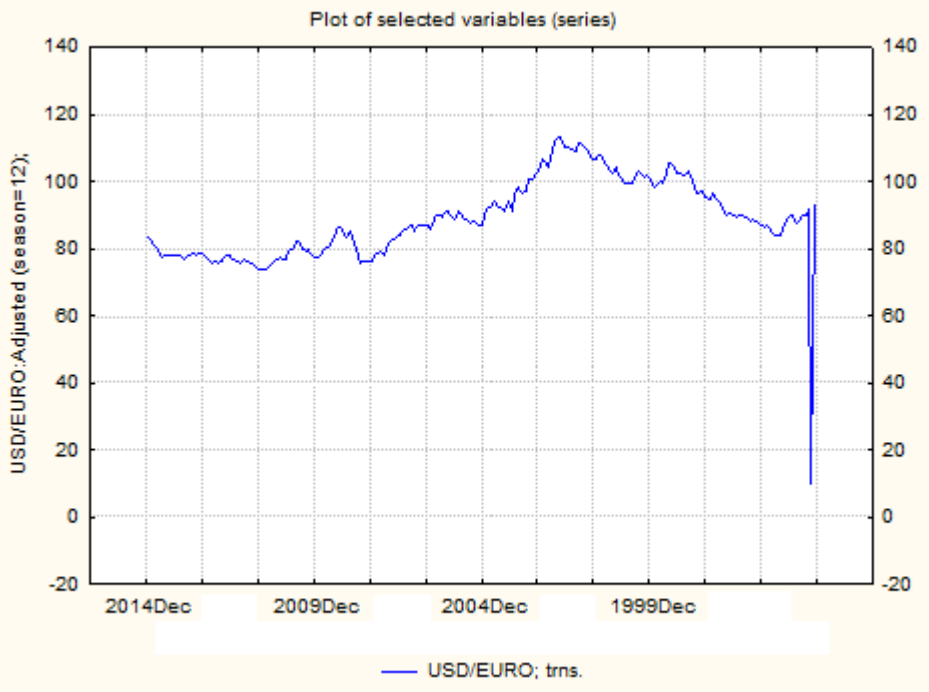
Iz prikazane tablice je uočljivo kako je pad tečaja USD zabilježen tijekom ljetnih i zimskih mjeseci, što se također odnosi na rast tečaja USD.

Nadalje, u radu će se prikazati i desezonirane vrijednosti vremenskog niza koje prikazuju vrijednosti tečaja bez sezonskih utjecaja. Riječ je o vrijednostima koje se računaju na način da se originalne vrijednosti vremenskog niza podjele sa konačnim procjenama sezonskih indeksa, te se pomože sa 100:

y_1* = 83,5247 / 100,2118*100 = 83,3482 što znači da bi bez sezonskog utjecaja tečaj bi iznosio 83,3482.

y_2* = 82,3549 / 100,1774*100 = 82,2090 što znači da bi bez sezonskog utjecaja tečaj bi iznosio 82,2090.
y_3* = 80,8473 / 99,7300*100 = 81,0662 što znači da bi bez sezonskog utjecaja tečaj bi iznosio 81,0662,

Ostale vrijednosti izračunavaju se na isti način.



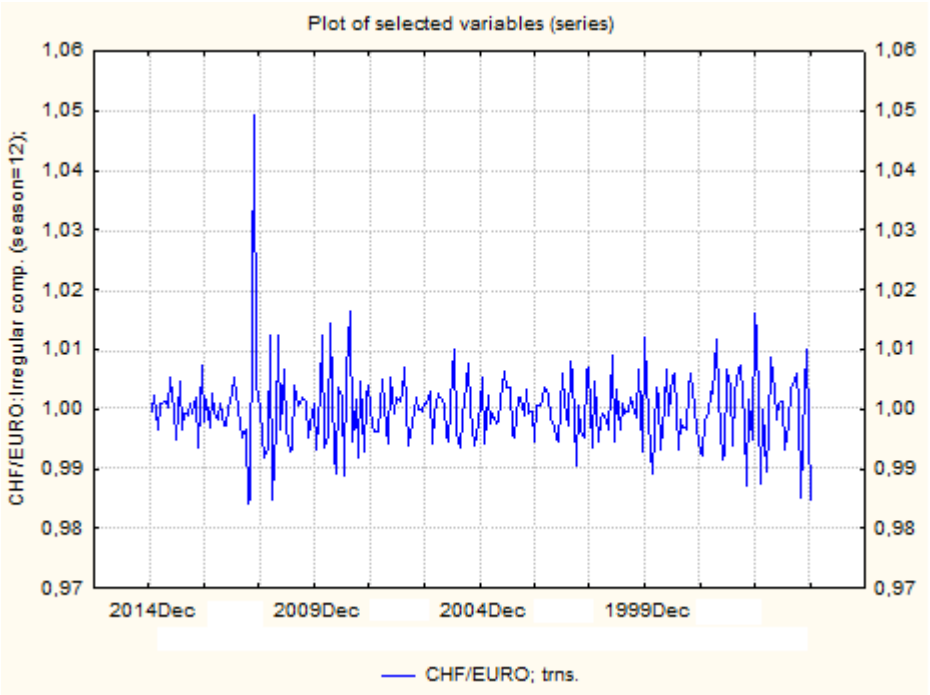
Grafikon 22. Desezonirane vrijednosti tečaja USD

Izvor: izrada autora

Kao posljednji korak izračuna koriste se faktori rezidualnih odstupanja (iregularna komponenta). Ovaj faktor, odnosno indeks dobije se tako da se desezonirane vrijednosti podjele sa vrijednostima na koje nema sezonskih utjecaja.

$I_{1,e}$ = 83,3482 / 82,7704*100 = 100,6980
$I_{2,e}$ = 82,2090 / 82,2078*100 = 100,0015

Na isti način računaju se i ostale vrijednosti.

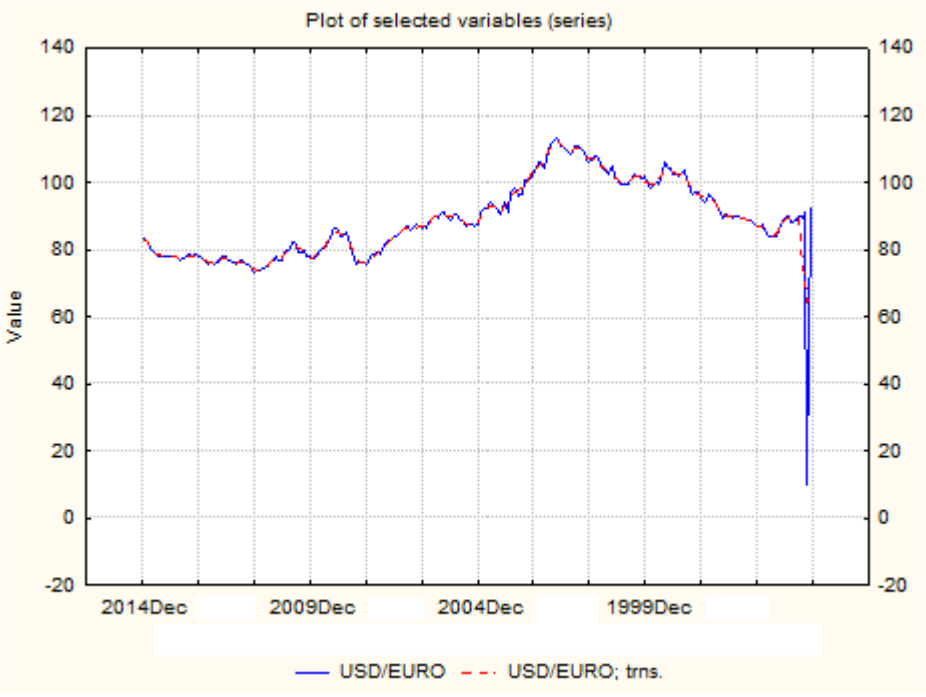


Grafikon 23. Iregularna komponenta tečaja CHF

Izvor: izrada autora

Vrijednosti promatranog vremenskog niza za prva dva opažanja imaju mogućnost dekomponirati se na sljedeći način:

83,5247 = 182,7704*(100,2118/100)*(100,6980/100)



Grafikon 24. Usporedba originalnog vremenskog niza tečaja USD i izglađene trend-cikličke vrijednosti

Izvor: izrada autora

5. ZAKLJUČAK

U ovom završno radu obrađena je tema kretanja tečaja Eura u razdoblju od 1995. godine do 2015. godine, što je dovelo do nekoliko bitnih zaključaka na ovu temu. Tečaj Eura jest jedan od najvažnijih faktora za razvoj gospodarstva, te isto tako utječe i na kvalitetu života svih ljudi.

Devizni tečajevi predstavljaju relacije između izraženih cijena domaćeg i stranog novca, odnosno devizni tečaj prikazuje cijenu domaće valute izraženu u stranoj valuti, i obrnuto. Euro kao valuta počela se koristi 1. siječnja 1999. godine kada je u EU bilo svega 12 zemalja, dok je do danas taj broj porastao na 19 zemalja članica.

Na tečaj Eura utječu i objektivni i subjektivni čimbenici. On se formira na međunarodnom tržištu deviza, a banke se javljaju kao najveći kupci ili prodavači deviza. Kao što je već navedeno, devizni tečaj ovisi o ponudi i potražnji na tržištu. Tako će u slučaju rasta potražnje devizni tečaj također rasti, dok će se smanjivati u situacijama kada potražnja za njim pada.

Na temelju provedenog istraživanja kretanja tečaja Eura u odnosu na franak, kunu, funtu i dolar, može se zaključiti da Euro ima najveće oscilacije kada je riječ o američkom dolaru. Tijekom 1995. godine vrijednost 100 dolara bila je oko 87 Eura, što je znatno manje u odnosu na prethodna razdoblja. Nakon 1995. godine, vrijednost 100 USD konstantno raste te se penje na vrijednost od 111 Eura, što je najveća zabilježena vrijednost u periodu koji je obuhvaćen istraživanjem.

Osim američkog dolara, velike oscilacije Euro ima i u odnosu na britansku funtu. U 2000. godini tečaj eura u odnosu na britansku funtu ima najveću najveću vrijednost te iznosi oko 106 eura. Navedena vrijednost zadržala se sve do 2008. godine, nakon čega ta vrijednost naglo pada (deprecijacija tečaja eura). Najniža vrijednost eura bila je 2009. te je iznosila 76 eura.

Analizirajući kretanje tečajeva trend modelima, može se zaključiti da su svi modeli značajni za odabrane valute. Osnovni razlog zašto su svi modeli značajni za odabrane valute leži u vremenskom razdoblju koje je obuhvaćeno istraživanjem.

Na temelju analize sezonskih varijacija može se zaključiti kako kuna najviše raste tijekom ljeta odnosno u šestom, sedmom i osmom mjesecu u godini. Britanska funta najveći rast ima u prvoj polovici godine, tj. do pet ili šestog mjeseca. Što se tiče švicarskog franka i američkog dolara, njihova kretanja slična su tijekom cijele godine.

LITERATURA

1. Babić, M.; Babić, A.(2008): Međunarodna ekonomija. MATE, Zagreb
2. Ćurak M., Jakovčević D. (2007): Osiguranje i rizici., RRiF plus, Zagreb
3. Hoffman, H.S. (1985.): Statistics Explained, University Press of America, Lanham
4. http://limun.hr/main.aspx?id=12393&Page=2; pristupljeno [16.9.2016.]
5. Izvor: http://sdw.ecb.europa.eu/quickview.do?SERIES_KEY=120.EXR.M.E1.USD.EN00.A ; pristupljeno [17.9.2016.]
6. Pcrišin, I., Šokman, A., Lovrinović, I. (2001): Monetama politika Fakultet ekonomije i turizma „Dr. Mijo Mirković“, Pula
7. Pivac, S. (2000): Statističke metode, Ekonomski fakultet, Split
8. Pivac, S. (2010.): Statističke metode, Ekonomski fakultet u Splitu, Split
9. Rozga, A. (2003): Statistika za ekonomiste. Ekonomski fakultet u Splitu
10. Rozga, A. (2006): Statistika za ekonomiste. Ekonomski fakultet, Split
11. Rozga, A., Grčić, B. (2010): Poslovna statistika Veleučilište u Splitu, Split
12. Rozga. A., Grčić, B. (2000): Poslovna statistika, Veleučilište u Splitu, Split

POPIS TABLICA

Tablica 1. Jednostavni linearni trend GBP/EURO.....22
Tablica 2. Jednostavni linearni trend HRK/EURO.....23
Tablica 3. Jednostavni linearni trend USD/EURO.....24
Tablica 4. Jednostavni linearni trend CHF/EURO.....25
Tablica 5. Logaritamska parabola GBP/EURO.....26
Tablica 6. Logaritamska parabola HRK/EURO.....27
Tablica 7. Logaritamska parabola CHF/EURO.....28
Tablica 8. Logaritamska parabola USD/EURO.....29
Tablica 9. Tablica 1. Dekompozicija vremenskog niza tečaja HRK multiplikativnom metodom.....30
Tablica 10. Prosječni sezonski indeksi, korekcije i stope promjene tečaja HRK.....33
Tablica 11. Tablica 1. Dekompozicija vremenskog niza tečaja GBP multiplikativnom metodom.....37
Tablica 12. Prosječni sezonski indeksi, korekcije i stope promjene tečaja GBP.....40
Tablica 13. Tablica 1. Dekompozicija vremenskog niza tečaja CHF multiplikativnom metodom.....44
Tablica 14. Prosječni sezonski indeksi, korekcije i stope promjene tečaja CHF.....47
Tablica 15. Tablica 1. Dekompozicija vremenskog niza tečaja USD multiplikativnom metodom.....51
Tablica 16. Prosječni sezonski indeksi, korekcije i stope promjene tečaja USD.....54

POPIS GRAFIKONA

Grafikon 1. Kretanje efektivnog deviznog tečaja između Eura i američkog dolara (USD)...18
Grafikon 2. Grafikon 1. Kretanje efektivnog deviznog tečaja između Eura i hrvatske kune (HRK).....19
Grafikon 3. Grafikon 1. Kretanje efektivnog deviznog tečaja između Eura i švicarske franke (CHF).....20
Grafikon 4. Grafikon 1. Kretanje efektivnog deviznog tečaja između Eura i britanske funte (GBP).....21
Grafikon 5. Centrirani pomični prosjek tečaja HRK.....31
Grafikon 6. Prve procjene sezonskih indeksa tečaja HRK.....32
Grafikon 7. Desezonirane vrijednosti tečaja HRK.....34
Grafikon 8. Iregularna komponenta tečaja HRK.....35
Grafikon 9. Usporedba originalnog vremenskog niza tečaja eura i izglađene trend-cikličke vrijednosti.....36
Grafikon 10. Centrirani pomični prosjek tečaja GBP.....38
Grafikon 11. Prve procjene sezonskih indeksa tečaja GBP.....39
Grafikon 12. Desezonirane vrijednosti tečaja GBP 41
Grafikon 13. Iregularna komponenta tečaja GBP.....42
Grafikon 14. Usporedba originalnog vremenskog niza tečaja GBP i izglađene trend-cikličke vrijednosti.....43
Grafikon 15. Centrirani pomični prosjek tečaja CHF.....45
Grafikon 16. Prve procjene sezonskih indeksa tečaja CHF.....46
Grafikon 17. Desezonirane vrijednosti tečaja CHF.....48
Grafikon 18. Iregularna komponenta tečaja CHF.....49
Grafikon 19. Usporedba originalnog vremenskog niza tečaja CHF i izglađene trend-cikličke vrijednosti.....50
Grafikon 20. Centrirani pomični prosjek tečaja USD.....52
Grafikon 21. Prve procjene sezonskih indeksa tečaja USD.....53
Grafikon 22. Desezonirane vrijednosti tečaja USD.....55
Grafikon 23. Iregularna komponenta tečaja CHF.....56
Grafikon 24. Usporedba originalnog vremenskog niza tečaja USD i izglađene trend-cikličke vrijednosti.....57

SAŽETAK

Statistika predstavlja granu znanosti gdje je osnovni cilj ostvariti postavljene ciljeve istraživanja, i to prikupljanjem, odabirom, prezentiranjem podataka, te njihovim interpretiranjem. U završnom radu provedena statistička analiza kretanja tečaja Eura u razdoblju od 1995. godine do 2015. godine. Devizni tečaj predstavlja cijenu domaće valute koja je izražena u stranoj valuti, što vrijedi i obrnuto. Istraživanje obuhvaća četiri različite valute, kuna, franak, dolar i funta. Najveće oscilacije vrijednosti valuta javljaju se između Eura i dolara, a nakon toga dolazi britanska funta, dok kuna i franak nemaju velikih oscilacija u promatranom vremenu. Također, Analizirajući kretanje tečajeva trend modelima, može se zaključiti da su svi modeli značajni za odabrane valute.

Ključne riječi: devizno tržište, statistička analiza, Euro, tečaj.

SUMMARY

Statistics represents a branch of science based on a main goal,which is to achieve the established research goals, by collecting, choosing, presenting and interpreting the information. This thesis is concerned with the statistical analysis of the currency rate of Euro in the period from 1995. to 2015. The currency rate is the price of the home currency represented through a foreign currency, and the other way around. The research represents four different types of currency, Croatian kuna, Swiss franc, American dollar and British pound. The main differences are seen between the Euro and the American dollar, followed by the British pound, while the Croatian kuna and the Swiss franc don’t show a significant variation during the time of the conducted analysis. Moreover, the analysis of the currency rate by trend models leads us to the conclusion that the chosen models are appropriate for the chosen currency.

Key words: currency market, statistical analysis, Euro, currency rate.