ANALIZA UTJECAJA RIZIKA DRŽAVE NA TROŠAK FINANCIRANJA HRVATSKIH PODUZEĆA

Longin, Sanja

Master's thesis / Specijalistički diplomski stručni

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:124:374503

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

ANALIZA UTJECAJA RIZIKA DRŽAVE NA TROŠAK FINANCIRANJA HRVATSKIH PODUZEĆA

Mentor:
Izv. prof. dr. sc. Roberto Ercegovac

Studentica:
Sanja Longin

Split, rujan 2016.

SADRŽAJ:

1. UVOD 4

1.1. Definiranje problema istraživanja 4

1.2. Ciljevi istraživanja 4

1.3. Metode istraživanja 5

1.4. Struktura rada 5

2. POJAM RIZIKA I NJEGOV KVANTITATIVNI IZRAZ 7

2.1. Pojam i mjerenje rizika 7

2.2. Utjecaj rizika države na kamatne stope 10

3. ANALIZA POKAZATELJA SISTEMSKOG RIZIKA RH 12

3.1. Pojam sistemskog rizika 12

3.2. Mjerenje sistemskih rizika 13

3.3. Sistemski rizici u RH 17

4. MEHANIZMI TRANSFERA RIZIKA DRŽAVE NA TROŠAK FINANCIRANJA GOSPODARSTVA 20

4.1. Politika kamatnih stopa u bankama 20

4.2. Transfer rizika države na trošak financiranja gospodarstva 23

5. ANALIZA UTJECAJA RIZIKA DRŽAVE NA TROŠAK FINANCIRANJA HRVATSKIH PODUZEĆA 26

6. OČEKIVANJE KRETANJA RIZIKA DRŽAVE U ODNOSU NA REALNE I FINANCIJSKE PARAMETRE GOSPODARSTVA 37

7. ZAKLJUČAK 41

LITERATURA 43

POPIS ILUSTRACIJA 46

Popis tablica 46

Popis slika 46

SAŽETAK **48**

SUMMARY **48**

PRILOZI **49**

1. UVOD

1.1. Definiranje problema istraživanja

Rizik države i njegov utjecaj na trošak financiranja gospodarstva predstavlja empirijski problem koji će se obraditi u ovom radu. Analizirat će se ovisnost troška financiranja hrvatskih poduzeća o riziku zemlje kroz praćenje premije kreditnog rizika zemlje.

Specifičnost rizika zemlje je njegova pojava u dva temeljna oblika i to sistemski i nesistemski Rizik zemlje pojavljuje se u funkciji sistemskog rizika kada država djeluje preko institucija na poslovne subjekte unutar gospodarskog sustava jedne zemlje, dok zaduživanje zemlje vodi do pojave rizika zemlje u funkciji nesistemskog ili kreditnog rizika zemlje.

Budući da se rizik zemlje uz referentnu kamatnu stopu uzima kao osnovica troška financiranja, postoji zavisnost troška financiranja o veličini rizika zemlje. Ključno je pitanje kako se promjena rizika države odražava na investicijske aktivnosti. Stoga je važno promatrati rizik zemlje kao odrednicu troška financiranja gospodarstva

1.2. Ciljevi istraživanja

Temeljni cilj ovog rada jest utvrditi ovisnost rizika države i troška financiranja hrvatskih poduzeća.

Dodatni ciljevi ovog rada jesu definiranje pojma rizika, uz naglasak na rizik države. Nadalje će se kvantificirati premija kreditnog rizika primjenom standardnih i naprednih pokazatelja, a poseban naglasak stavit će se na analizu ovih pokazatelja u Republici Hrvatskoj, zatim će se utvrditi kojim mehanizmima se transferira rizik države na trošak financiranja gospodarstva. Također, cilj je pretpostaviti kakva su očekivanja kretanja rizika države u odnosu na realne i financijske parametre gospodarstva.

Konačni cilj je na jednom mjestu sistematizirati najvažnija postignuća i spoznaje o kreditnom riziku države i njegov utjecaj na trošak financiranja hrvatskih poduzeća.

1.3. Metode istraživanja

Temeljne znanstvene metode koje će se primjenjivati u radu jesu metode analize i sinteze, gdje se putem analize složeni zaključci raščlanjuju na njihove jednostavnije sastavne dijelove, a sinteza omogućuje spajanje odnosno povezivanje izdvojenih pojava i odnosa u jedinstvenu cjelinu. Za donošenje relevantnih zaključaka koristit će se induktivna metoda koja omogućuje donošenje zaključaka o općem sudu na temelju posebnih ili pojedinačnih činjenica, te deduktivna metoda kojom se iz općih stavova izvode posebni ili pojedinačni zaključci. Za jednostavno opisivanje činjenica koristit će se metoda deskripcije, te metoda klasifikacije pri formiranju različitih podjela.

Za istraživanje praktičnog dijela rada koristit će se povijesna metoda za prikupljanje serija vremenskih podataka kretanja tržišnih vrijednosti CDS-a, tržišnih kamatnih stopa te kamatnih stopa za devizne kredite. Prikupljeni podaci služit će za obradu pomoću statističke metode. Metodom komparacije uspoređuju se dobiveni rezultati s drugim rezultatima.

1.4. Struktura rada

Rad s tematikom rizika države i njegova refleksija na trošak financiranja hrvatskih poduzeća podijeljen je na sedam tematskih cjelina. Rad je konstruiran na način da se od općih teorijskih pretpostavki rizika države ide prema specifičnom problemu rizika RH i načinu njegova transferiranja na trošak financiranja hrvatskih poduzeća. Stoga će u nastavku biti izložen kratki pregled poglavlja rada kao i glavni elementi tih poglavlja.

U uvodnom dijelu (1) objašnjava se problem istraživanja, zatim se determiniraju ciljevi koji se žele postići pisanjem rada te znanstvene metode koje će se koristiti u svrhu istraživanja. Na kraju poglavlja bit će napravljen pregled cjelokupne strukture rada prema poglavljima s osvrtom na glavne pojmove svake cjeline.

Drugi dio (2) bavi se pojmom rizika te njegovim podjelama na opće i poslovne rizike, a poseban naglasak bit će stavljen na rizik zemlje koji spada u skupinu općih rizika. Obradit će se i mjere rizika te utjecaj rizika države na kamatne stope.

Treći dio (3) ukratko će objasniti pojam sistemskog rizika te njegove glavne izvore, a zatim će se kvantificirati premija rizika države korištenjem standardnih i naprednih pokazatelja premije kreditnog rizika države. Zatim će se analizirati kreditni rejting te kamatni rasponi u Hrvatskoj.

Četvrti dio (4) objašnjava mehanizme kojima se rizik države transferira na trošak financiranja gospodarstva. U ovom dijelu objasnit će se politika kamatnih stopa u bankama te interna ekonomija banke odnosno kroz profitne, troškovne i pseudoprofitne centre objasnit će se organizacijska struktura komercijalne banke.

U petom dijelu (5) provedena je analiza utjecaja rizika zemlje na trošak financiranja gospodarstva, predstavljen kao visina kamatnih stopa.

U šestom dijelu (6) opisano je očekivano kretanje rizika Republike Hrvatske s obzirom na neke parametre gospodarstva.

Sedmi dio (7) rada je zaključak. U zaključnom dijelu iznijet će se glavni rezultati i spoznaje do kojih se došlo u istraživanju, te će se ukazati na (ne)podudaranje teorijskih spoznaja i empirijskih dokaza.

2. POJAM RIZIKA I NJEGOV KVANTITATIVNI IZRAZ

U ovom dijelu rada objasnit će se osnovna definicija rizika te podjela rizika na opće i poslovne rizike. Detaljnije će se obraditi rizik zemlje koji je svakako najvažniji za ovaj rad. U drugom dijelu objasnit će se utjecaj rizika države na kamatne stope.

2.1. Pojam i mjerenje rizika

Jedna od najjednostavnijih definicija rizik definira kao razliku između onoga što se očekivalo i onoga što je ostvareno. Postoje mnoge vrste rizika, ali dvije osnovne podjele prema kojima se dalje klasificiraju rizici su podjela na opće i poslovne rizike.

Opći rizici koji se još nazivaju i sistemski rizici, nastaju izvan poslovnog subjekta te ti poslovni subjekti nemaju veliki utjecaj na njihovu učestalost i intenzitet, a što predstavlja njihov egzogeni karakter. Opći rizici se dijele na rizik makroekonomske politike, rizik legislative, rizik konjunkture, tržišni rizik, rizik nenadanih događaja, rizik neizgrađenosti institucija te posebno značajan u ovom istraživanju, rizik države.

Poslovni rizici s druge strane se još zovu i nesistemski rizici, jer pogađaju samo neke poslovne subjekte, a njihov izvor je unutar samog poslovnog subjekta, što znači da oni svojim djelovanjem izravno utječu na intenzitet pojavljivanja poslovnih rizika. Oni se dijele na operativni rizik, kreditni rizik, rizik likvidnosti, rizik ugleda, rizik zakonodavstva, rizik solventnosti te pravni rizik.

Za ovaj rad je svakako najznačajniji rizik države, koji spada u opće rizike. Riječ je o specijalnom modalitetu kreditnog rizika, ali i specifičnog, jer banke najčešće od države nemaju alternativne izvore naplate potraživanja.[1]

Rizik zemlje je važan čimbenik kod donošenja investicijskih odluka inozemnih ulagatelja, te je stoga, osobito za tranzicijske zemlje koje nastoje privući inozemni kapital, važna ocjena ili

[1] Jakovčević, D. (2000): Upravljanje kreditnim rizikom u suvremenom bankarstvu, TEB Poslovno savjetovanje, Zagreb, str. 31.

rang kreditne sposobnosti zemlje koje im dodjeljuju za to specijalizirane ili ovlaštene svjetski priznate agencije.[2]

Procjena rizika zemlje ili rizika suverenosti se temelji na procjeni dugoročnog poslovnog okruženja u pojedinoj zemlji, a u tom smislu se fokusira sam financijski sektor i učinak koji bi na njega mogli proizvesti različitih ekonomski i politički čimbenici. Jedna od mogućih procjena obuhvaća iscrpno vaganje sljedećih čimbenika: zadnje ekonomske performanse, kvaliteta ekonomskog i financijskog menadžmenta, dubina i sofisticiranost tržišta, stabilnost ekonomske politike, stabilnost i djelotvornost političkog sustava te dugoročni trendovi i očekivane buduće performanse.

Razlikujemo dva pojavna oblika rizika države. Prvi pojavni oblik rizika države je sistemski rizik te se odnosi na snagu države da preko svojih institucija utječe na sve sudionike gospodarskog sustava. Ovaj pojavni oblik rizika države poslovni subjekti ne mogu izbjeći jer su preko zakonskih uvjeta, geografskog položaja ili financijskih tokova neposredno povezani s određenom državom. Drugi pojavni oblik rizika zemlje odnosi se na državu kao dužnika kod emitiranja državnog duga. Ovdje se država pojavljuje u funkciji izvora nesistemskog rizika prema drugim subjektima. Pretpostavlja se da država funkcionira kao poslovni subjekt te su joj potrebna određena financijska sredstva. U ovom slučaju rizik države poistovjećuje se s kreditnim rizikom zemlje.

Druga karakteristika rizika zemlje su dva načina refleksije ovog rizika na sudionike gospodarskog sustava. Prvi način refleksije je prilikom zaduživanja poslovnih subjekata na međunarodnom tržištu kapitala, dok je drugi način refleksije kod direktnog zaduživanja domaćih poslovnih subjekata na domaćem tržištu kapitala.

Rizik države uključuje politički i ekonomski rizik.[3] Politički rizik se može definirati kao vjerojatnost da zemlja dužnik ili dužnik iz neke zemlje ne može ili nije voljan izvršiti svoje dugovne obveze zbog političkih faktora. Najčešće korišten način mjerenja političkog rizika je postavljanje pitanja sa mogućim odgovorima koji nose određeni broj bodova.[4] Sukladno ostvarenom broju bodova, zemlja se rangira u jednu od pet kategorija: visoko rizična, nisko rizična, srednje rizična, blago rizična ili bezrizična zemlja. Ekonomski rizik se može definirati kao vjerojatnost da dužnik iz neke zemlje ili zemlja kao dužnik neće biti u mogućnosti servisirati svoje dugove zbog izrazito nepovoljnih gospodarskih kretanja u zemlji. Ekonomski

[2] Jakovčević, D.: op. cit., str. 31.
[3] Koch, W. T., MacDonald, S. S. (1992): Bank management, The Dryden Press, Fort Worth, str. 841-843.
[4] Bodie, Z., Kane, A., Marcus, A.: Investments, 7th edition, Mcgraw-Hill Irvin, New York, 2008., p. 906.-909

rizik se obično mjeri ekonomskim pokazateljima i pokazateljima upravljanja dugom.[5] Ekonomski pokazatelji mogu biti stopa rasta BDP-a, BDP po glavi stanovnika, stopa inflacije, javni dug, stopa nezaposlenosti, razina kamatnih stopa, broj inicijalnih javnih ponuda društava u odnosu na prethodna razdoblja itd. Pokazatelji upravljanja dugom mogu biti odnos inozemnog duga i BDP-a, odnos inozemnog duga i izvoza robe i usluga, odnos otplaćenog inozemnog duga i izvoza robe i usluga, stope rasta inozemnog i javnog duga u odnosu na prethodna razdoblja.

Rizik se može operacionalizirati kao odstupanje stvarnih od očekivanih vrijednosti događaja. Srednje kvadratno odstupanje stvarnih od očekivanih vrijednosti predstavlja varijanca, koja se računa putem formule:

$$SD^2 = \frac{1}{n} \sum_{i-1}^{n} (x_i - E(x))^2 \quad (1)$$

Pri čemu je:
SD^2 – varijanca
n – niz statistički promatranog događaja $x_1, x_2 \ldots x_n$

Često se kao mjera rizika pojave koristi standardna devijacija, odnosno jedinična mjera disperzije:

$$SD = \frac{1}{n} \sum_{i-1}^{n} (x_i - E(x))^2 \quad (2)$$

Veće raspršenje događaja oko njegove prosječne očekivane vrijednosti predstavlja i veći rizik promatrane pojave.

Međutim, varijanca i standardna devijacija ne oslikavaju jasno moguće gubitke uslijed promjene tržišnih parametara pa se u svijetu financija danas najčešće koristi mjera rizik VaR (eng. *Value at risk*). VaR je novčano izražen iznos najgoreg mogućeg gubitka vrijednosti ili prihoda tokom određenog horizonta uz normalne tržišne uvjete na razini zadane značajnosti procjene.[6] Koriste se dva izraza VaR-a: parametrijski i neparametrijski. Parametrijski koristi teorijske distribucije pri izračunu, dok neparametrijski ne upotrebljava teorijske već

[5] Koch, W. T.: op. cit., p. 842
[6] Jorion, P. (2001): Value at Risk, The New Benchmark for Managing Financial Risk, McGraw-Hill Inc, New York.

empirijske distribucije za izračun njegove vrijednosti. VaR se uvije računa s obzirom na neki vremenski period, pri čemu njegova vrijednost govori o potencijalnom gubitku u danom vremenskom razdoblju. Odredi li se stupanj značajnosti od 95%, izračunati VaR pokazuje maksimalni mogući gubitak u 95% slučajeva.

2.2. Utjecaj rizika države na kamatne stope

Rizik države osobito je važan za investitore koji su skloni riziku te sukladno svojim preferencijama ulažu u zemlje koje su svrstane u rizičnu i visokorizičnu kategoriju gdje je i povrat na uloženo znatno viši od povrata na investicije u zemlje koje su u kategoriji blage ili srednje rizičnosti. Značajni faktori koji utječu na formiranje kamatnih stopa su inflacija, stvarna kamatna stopa, rizik neplaćanja, rizik likvidnosti, rok dospijeća te ugovorena ograničenja.

S vremenom je porastao utjecaj rizika države na strukturu kamatnih stopa te se mijenjao i utjecaj ovog rizika na efikasnost financijskog sustava. Značajno je naglasiti da će kamatne stope ovisiti o riziku koji je karakterističan za neku zemlju, tako da što je veća razlika u rizičnom profilu između zemalja, to će biti i veći kamatni raspon između kamatnih stopa tih zemalja. Radi se o tome da kako investitori zahtijevaju veće povrate na ulaganje u rizičnije zemlje od zemalja koje su bezrizične, razlika u povratima na ulaganje u dvije zemlje različitih rizičnih profila naziva se premija rizika države ili jednostavno razlika (eng. *spread*).

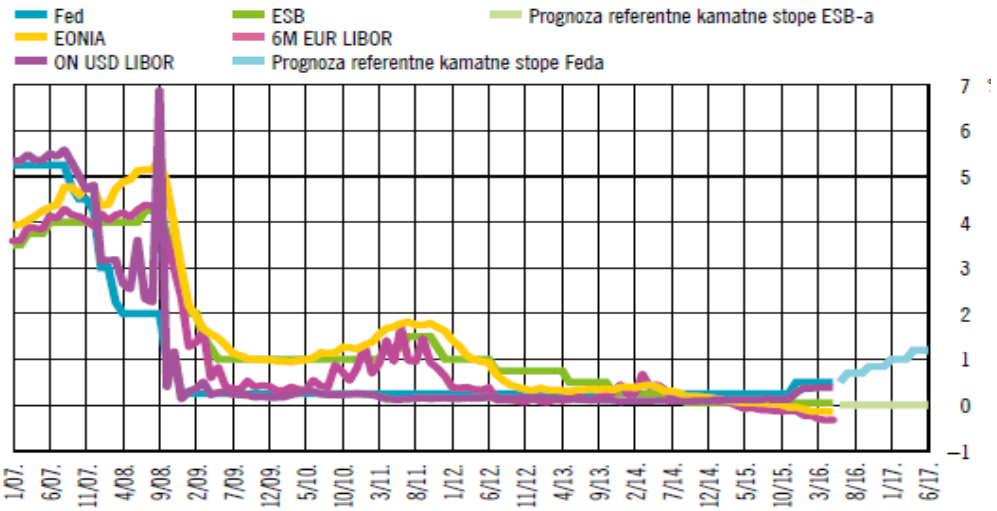
Budući da je kamatna stopa trošak za korisnike posuđenih sredstava, svako povećanje kamatnih stopa potaknuto pogoršanjem kreditnog ranga zemlje poskupljuje jednako i postojeća zaduženja i nova zaduženja. Rast kamatnih stopa poslovnim subjektima dovodi do smanjenja broja projekata koji su ekonomski isplativi jer se moraju diskontirati po novoj uvećanoj diskontnoj stopi te do povećanog odljeva likvidnih sredstava iz poslovnih subjekata zbog plaćanja većih kamata, a posljedično dolazi do smanjenja investicijskog potencijala poslovnih subjekata i do smanjenja konkurentnosti cjelokupnog gospodarstva jedne zemlje.[7]

Model koji se obično koristi za identifikaciju faktora koji određuju razinu kamatnih stopa u bilo kojem trenutku kao i uzroke kretanja kamatnih stopa tijekom vremena je teorija o

[7] Duvnjak, N., Mišura, M., Slišković, Ž. (2011): Bankovni management: Rizik zemlje - utjecaj na financijski sustav i pregled procjena, Ekonomski fakultet, Split, str. 6.

posuđenim sredstvima.[8] Prema njoj, visina ravnotežnih kamatnih stopa na financijskim tržištima je rezultat činitelja koji utječu na ponudu i potražnju za posuđenim sredstvima, a to je slično načinu na koji se cijene roba i usluga, općenito gledano, smatraju rezultatom sila ponude i potražnje za tim robama i uslugama.

Promjena kamatne stope uzrokuje kretanje po krivuljama ponude i potražnje pozajmljivih sredstava dok promjene ostalih faktora uzrokuju pomake krivulja ponude i potražnje. Nerizična realna (inflacijski prilagođena) kamatna stopa se mijenja tijekom vremena s promjenama ponude i potražnje kreditnih sredstava. Postoje različite vrste nerizičnih kamatnih stopa kao što su prime stopa, stopa na korporacijske obveznice te povrat na vladine obveznice.[9]



Grafikon 1: Kretanje referentnih kamatnih stopa na tržištu novca (2007.-2016)

Izvor: HNB, Financijska stabilnost (17), str. 10

Na grafikonu 1 su prikazane referentne kamatne stope s četiri tržišta novca u periodu od 2007. do 2016. te prognoze za 2017. godinu. Radi se o kamatnoj stopi na tržištu novca koju za američko tržište propisuju američka središnja banka ili FED, za Eurozonu referentnu kamatnu stopu propisuje europska središnja banka ili ESB, i prekonoćnoj kamatnoj stopi na londonskom međubankarskom tržištu novca. Ova tržišta novca su predmet usporedbe i osnova za utvrđivanje troška zaduživanja u rizičnijim zemljama.

[8] Saunders, A., Cornett, M. M. (2006): Financijska tržišta i institucije: moderno viđenje, Masmedia, Zagreb, str. 37.
[9] Miller, L. R., VanHoose, D. D. (1997): Moderni novac i bankarstvo, Mate, Zagreb, str. 144.-148.

3. ANALIZA POKAZATELJA SISTEMSKOG RIZIKA RH

Treće poglavlje ovog rada posvećeno je analizi pokazatelja sistemskog rizika. Prvo će se definirati sistemski rizik, sistemski događaj u užem i širem smislu te najčešći izvori sistemskog rizika. Zatim će se analizirati dvije osnovne vrste pokazatelja rizika zemlje: tradicionalni i suvremeni pokazatelji. U posljednjem dijelu ovog poglavlja ovi pokazatelji analizirat će se na primjeru Republike Hrvatske.

3.1. Pojam sistemskog rizika

Sistemski rizik jest prijetnja da će poremećaji u financijskom sustavu rezultirati ozbiljnim negativnim posljedicama za cjelokupno financijsko tržište i realno gospodarstvo. Vrlo je vjerojatno da će se tijekom vremena u financijskom sustavu akumulirati određena razina rizika koji mogu narušiti njegovu stabilnost i ugroziti proces financijskog posredovanja. Materijalizacija tog rizika čini sistemski događaj. Razlikujemo sistemske događaje u užem i u širem smislu. Oni u užem smislu obuhvaćaju situacije kada nepovoljni događaji ili vijesti vezani uz neku financijsku infrastrukturu rezultiraju nizom negativnih posljedica za jednu ili više drugih institucija, ili dio financijskog tržišta. Širi koncept sistemskog događaja uključuje i simultane negativne učinke uzrokovane sistemskim šokom koji pogađaju velik broj financijskih institucija ili tržišnih segmenata.

Izvori sistemskog rizika nalaze se i unutar financijskog sustava i izvan njega. Endogeni rizici obuhvaćaju institucionalne rizike, poput operativnog ili financijskog rizika, tržišne rizike te infrastrukturne rizike koji se mogu odnositi na sustav poravnanja, platni sustav ili sustav namire; dok se u egzogene rizike ubrajaju makroekonomski poremećaji koji mogu biti povezani s okružjem ili globalnim neravnotežama i rizici nepredviđenih događaja poput vremenskih nepogoda, terorističkih napada ili političkih događaja.[10]

Glavni izvori sistemskog rizika su kreditni rizik, tržišni rizik, operativni rizik, rizik likvidnosti, rizik povezan s infrastrukturom i rizik zaraze. *Kreditni rizik* definiramo kao rizik gubitka zbog neispunjavanja dužnikove novčane obveze prema kreditnoj instituciji. *Tržišni rizik* se definira kao vjerojatnost gubitka imovine poslovnog subjekta uslijed nenadanih

[10] Dumičić, M. (2015): Pokazatelji financijske stabilnosti – primjer Hrvatske, HNB, Zagreb.

promjena deviznog tečaja, kamatnih stopa, tečaja vlasničkih udjela u drugim poslovnim subjektima i cijena roba i usluga na tržištu. *Operativni rizik* predstavlja vjerojatnost da će nedostaci informacijskih sustava ili unutrašnje kontrole rezultirati neočekivanim gubitkom za poslovne subjekte. *Rizik likvidnosti* je vjerojatnost nastupa štetnog događaja kojega karakterizira nemogućnost poslovnog subjekta da izvršavati sve svoje kratkoročne obveze. *Rizik infrastrukture* snažno je povezan s operativnim rizikom. Rizik bankovne zaraze je sistemski rizik koji proizlazi iz propasti bankarskih institucija.

3.2. Mjerenje sistemskih rizika

Pokazatelji premije rizika države mogu se podijeliti u dvije skupine: standardni i napredni. Standardni (tradicionalni) pokazatelj rizika zemlje je kreditni rang dodijeljen od strane agencija za dodjelu kreditnog ranga, a napredni (suvremeni) pokazatelji rizika zemlje mogu biti utemeljeni na analizi kreditnog rizika države pomoću premije rizika javnog duga (s*pread* analiza javnog duga) ili na analizi kreditnog rizika države pomoću ugovora o zamjeni kreditnog rizika (CDS s*pread*).

Institucije koje se bave procjenom rizika zemlje su agencije za kreditni rejting. Kreditna rejting agencija je specijalizirana tvrtka koja daje mišljenje o kreditnoj sposobnosti entiteta ili financijske obveze, kao što su obveznice, prioritetne dionice, komercijalni papiri.[11] Kreditni rejting definira se kao skup svojstava tražitelja kredita, kao što su položaj, imovina, poslovi i perspektiva, na temelju kojih je moguće donijeti ocjenu o njegovoj kreditnoj sposobnosti.[12] Kreditni rejting države pokazuje sposobnost i spremnost zemlje u otplati vanjskog i unutarnjeg duga te služi potencijalnim inozemnim investitorima kao svojevrsna slika stanja i perspektive ekonomije koji opredjeljuje njihovu odluku o ulaganju.[13]

[11] Pavković, A.: Kreditne rejting agencije: od marginalnih igrača ka neizostavnim specijalistima financijskog posredovanja, Računovodstvo i financije, Hrvatska zajednica računovođa i financijskih djelatnika, Zagreb, godina LVIII, 2012., p. 132.
[12] Leko,V., Mates, N. (1993): Rječnik bankarstva i financija, Masmedia, Zagreb.
[13] Bajo, A., Penava, J.: op. cit., p. 45.

Pri procjeni rizičnosti izdavatelja financijskih instrumenata kreditne rejting agencije koriste metodologiju koja analizira javno dostupne podatke vezane za izdavatelje, ali i podatke koji nisu javno dostupni.[14]

Osnovna svrha poslovanja rejting agencija jest uklanjanje asimetričnih informacija između izdavatelja financijskog instrumenta i potencijalnog investitora. Smanjenje informacijske asimetrije se postiže kroz javno objavljivanje dodijeljenih kreditnih rejtinga. Druga korist postojanja kreditnih rejting agencija je ta što omogućuju investitorima ulazak na tržište kapitala uz smanjenu cijenu kapitala.

Regulacija koja se temelji na rejtingu se može podijeliti u tri osnovne grupe: prva grupa regulacije se odnosi na politiku nadgledanja i regulacije pojedinih poduzeća na tržištu, druga se odnosi na regulaciju investicijskih odluka i treća grupa regulatornih instrumenata se odnosi na zadovoljenje kapitalnih zahtjeva.[15]
Jedna od najvažnijih funkcija rejtinga je standardizacija vrijednosnih papira čime se omogućuje uspoređivanje vrijednosnih papira i izdavatelja. Specifičnost poslovanja kreditnih rejting agencija je u tome da za štetu uzrokovanu lošim procjenama agencije, agenciju nije moguće pravno tužiti.

Pojedine zemlje, industrije i izdavatelji vrijednosnih papira imaju drugačija pravila i karakteristike i zbog toga se procjena rejtinga ne može isključivo svesti na korištenje ustaljenih formula.

Kreditne rejting agencije dodjeljuju ocjene za svaku organizaciju koja izdaje dužničke instrumente, uključujući i privatne korporacije i sve razine vlasti. S obzirom na to da investitori trebaju znati da primaju odgovarajuću naknadu za rizik od ulaganja, rejtinzi koje agencije izdaju su bitni za cijelu financijsku industriju. Kamatna stopa na dug obrnuto je povezana s njegovom razinom rizika, a budući da ulagači koriste mišljenje rejting agencije kao metriku za razinu rizika povezanog s dužničkim instrumentom, kreditne ocjene igraju ključnu ulogu u kamatnim stopama različitih dužničkih vrijednosnih papira.[16]

[14] Pavković, A., Vedriš, D. (2011): Redefiniranje uloge agencija za kreditni rejting u suvremenom financijskom sustavu, Ekonomska misao i praksa, (1), str. 225-250, [Internet], raspoloživo na: http://hrcak.srce.hr/69719, [06.07.2016.].
[15] Dittrich, F. (2007): The Credit Rating Industry: Competition and Regulation, doktorska disertacija, Department of Economics, Cologne, [Internet], raspoloživo na: http://ssrn.com/abstract=991821, [06.07.2016.].
[16] Katavić, M. (2015): Determinantne kreditnog rejtinga zemalja Europske unije, diplomski rad, Ekonomski fakultet, Split, str.16.

Ono što dužnici zapravo žele jest da investitori imaju dobru ideju o tome koliko su kreditno vrijedni njihovi vrijednosni papiri. Budući da su investitori u potrazi za objektivnom idejom o sposobnosti poduzeća da vrati dug, pa će stoga poduzeća zaposliti kreditne rejting agencije da ocijene dugove. Kada provode svoju procjenu, agencije za kreditni rejting će gledati niz faktora, uključujući razinu duga institucije, njegov karakter, iskaz svoje spremnosti da vrati dug i njegovu financijsku sposobnost da vrati svoj dug.

Kada se ocjenjuje kreditni rejting institucija, agencije će klasificirati dug kao jedan od sljedećih: visoka ocjena, gornja srednja ocjena, donja srednja ocjena, neinvesticijski rejting, špekulativna ocjena, vrlo špekulativna ocjena, značajniji rizici i neizvršenje novčanih obveza te neizvršenje novčanih obveza.

Ne postoji jedinstvena formula kojom se može odrediti kreditni rejting iz razloga što ocjena ekonomskih analitičara uz objektivne ekonomske pokazatelje, sadrži i subjektivnu procjenu.[17] Tako se ocjena kreditne sposobnosti izdavatelja vrijednosnih papira ne sastoji samo u promatranju i ocjenjivanju financijskih pokazatelja, već se u obzir uzima i pozicija poduzeća na tržištu, upravljanje poduzećem te strategije.

Pri donošenju rejtinga nekada u većoj mjeri sudjeluju poslovni, a nekada financijski rizici.[18] Metodologiju koja se koristi prilikom dodjele rejtinga potrebno je konstantno prilagođavati promjenama u gospodarstvu, uvjetima poslovanja, rizicima te posljedicama financijske krize.

U tablici 1. su prikazani standardni simboli kojima se prikazuje rejting, a oni se odnose na dugoročne kooperativne zadužnice, dok se u slučaju druge vrste vrijednosnih papira ili financijskih institucija mogu koristiti drugi simboli ili se postojeći simboli tumače na drugačiji način, ovisno o kojoj se vrsti vrijednosnih papira ili financijskih institucija radi.[19]

[17] Katavić, M.: op. cit., str. 23.
[18] Standard&Poor's: Rating Methodology: Evaluating the Issuer, [Internet], raspoloživo na: http://www2.standardandpoors.com/spf/pdf/fixedincome/methodology.pdf, [06.07.2016.].
[19] Pavković, A., Vedriš, D.: op. cit.

Tablica 1: Usporedba i opis ocjena rejtinga S&P i Moody's

S&P	Moody's	Opis značenja
AAA AA+	Aaa Aa1	Najviši rejting. Sigurno ispunjenje financijskih obaveza
AA AA- A+	Aa2 Aa3 A1	Vrlo visoka sigurnost ispunjenja financijskih obveza
A A- BBB+	A2 A3 Baa1	Visoka sigurnost, postoji osjetljivost na nepovoljne ekonomske uvjete
BBB	Baa2	Sigurnost ispunjenja obveza, postoji osjetljivost na nepovoljne ekonomske uvjete
BBB-	Baa3	Smatra se najnižom razinom investicijskog razreda
BB+	Ba1	Smatra se najvišom razinom špekulativnog razreda
BB BB- BB+	Ba2 Ba3 B1	Mala osjetljivost u kratkom roku, neizvjesnost u budućnosti
B B- CCC+	B2 B3	Veća osjetljivost tijekom loših ekonomskih uvjeta
CCC CCC-	Caa	Trenutna osjetljivost, ovisnost o povoljnim ekonomskim uvjetima
CC	Ca	Visoka osjetljivost
C	C	Visoka osjetljivost, mala vjerojatnost ispunjenja obveza
D		Nemogućnost ispunjenja financijskih obveza

Izvor: Moody's (2009): Rating Symbols & Definitions, str. 8, [Internet], raspoloživo na: http://media.al.com/bn/other/Moody's%20rating%20scale.pdf, [15.07.2016.].

Ugovor o zamjeni kreditnog rizika (eng.*credit default swap* - CDS) je vrsta kreditne izvedenice, pa se tako prodavatelj CDS-a obvezuje kupcu ugovora namiriti gubitak u slučaju nastanka kreditnog događaja, za što kupac plaća periodičnu naknadu. Kreditni događaj je bilo koji događaj definiran u ugovoru o kreditnoj izvedenici koji dovodi do namire po kreditnoj izvedenici i prestanka ugovornog odnosa.[20] CDS predstavlja najrašireniju vrstu kreditnih derivata. Takvi ugovori omogućavaju kreditorima da spuštaju ili sasvim neutraliziraju rizik bankrotiranja od strane dužnika za bilo kakav kredit, obveznice ili neku drugu vrstu pozajmice. Prema ugovoru o zamjeni kreditnog rizika kupac ugovora plaća niz isplata

[20] HNB (2013): Odluka o adekvatnosti jamstvenog kapitala kreditnih institucija, HNB, Zagreb, str. 6, [Internet], raspoloživo na: http://old.hnb.hr/propisi/odluke-nadzor-kontrola/odluke-zoki-ozujak-2010/h-odluka-o-adekvatnosti-jamstvenoga-kapitala-ki-od%2030-6-2012.pdf, [15.07.2016.].

prodavatelju ovog ugovora u zamjenu za isplatu dugovnih financijskih aktiva u slučaju nastupa bankrota izdavatelja dugovnih financijskih aktiva.[21]

Cijena koju kupac CDS-a plaća prodavatelju istoimenog ugovora za zaštitu u slučaju nastanka nekog od kreditnih događaja definiranih u ugovoru zove se CDS spread. CDS spread je godišnji iznos koji kupac plaća prodavatelju za zaštitu od bankrota izdavatelja dužničkih instrumenata. Kako i država izdaje dužničke instrumente, prodavatelji CDS-a nude zaštitu i za državne dužničke instrumente. *CDS spread* određuje prodavatelj na temelju vjerojatnosti bankrota države. U tom slučaju, CDS spread predstavlja premiju kreditnog rizika zemlje.

Prilikom ocjene vjerojatnosti nastupa bankrota prodavatelj ispituje iznose javnog duga, dodijeljeni kreditni rang, stopa rast BDP-a, stopa inflacije, volatilnost dioničkih indeksa, VaR, nagib krivulje prinosa, kretanje kamatnih stopa i indeks povjerenja potrošača.[22]

3.3. Sistemski rizici u RH

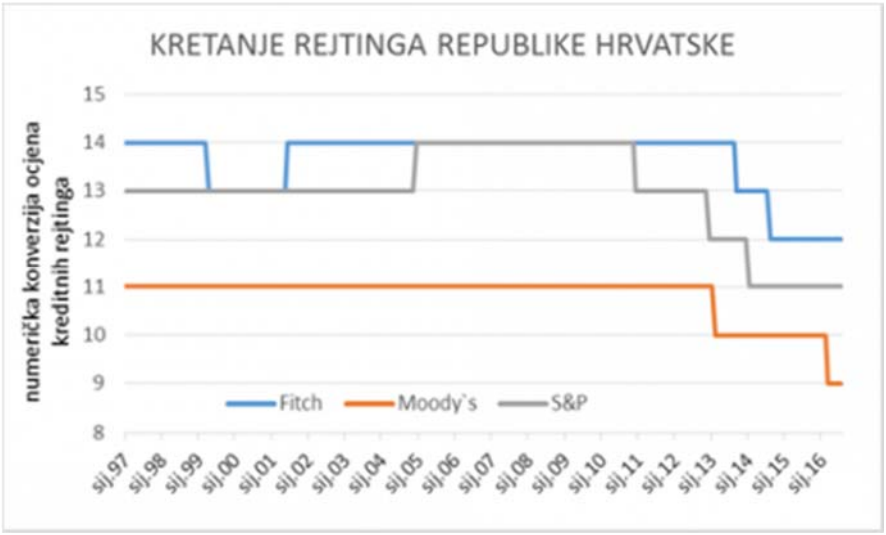
Kreditni rejting određuje uvjete zaduživanja i rizik investiranja u pojedinu zemlju, a Hrvatskoj se dodjeljuje od siječnja 1997. godine kada su ostvareni preduvjeti za uključivanje Hrvatske u analize vodećih svjetskih rang agencija.

U svom posljednjem razmatranju kreditnog rejtinga Hrvatske u srpnju ove godine, rejting agencije S&P i Moody´s i Fitch Ratings zadržale su ocjenu podinvesticijskog ranga. To je bilo i u skladu s očekivanjima, u okolnostima relativno skromnoga gospodarskog oporavka i latentne političke nestabilnosti. Kreditni rejting Hrvatske, ocijenjen kao podinvesticijski, prisutan je od prosinca 2012. g. (prema agenciji S&P), odnosno od 2013. g. (prema Moody`s i Fitch). Naime, sve tri vodeće kreditne agencije smatraju da zbog loših izgleda za gospodarski rast, brzorastućeg i visokog javnog duga i velikih proračunskih deficita, postoji znatan rizik za ulaganja, a izglede, koji predstavljaju očekivanja daljnjih kretanja, ocjenjuju negativnima.

Agencija Fitch Ratings 30. srpnja ove godine potvrdila je dosadašnji dugoročni kreditni rejting Hrvatske za zaduživanje u stranoj i domaćoj valuti na 'BB' i kratkoročni na 'B', a zadržala je i negativne izglede. Ovaj rejting odražava ravnotežu između, s jedne strane,

[21] Bluhm, C., Overbeck, L., Wagner, C.: An itroduction to credit risk modeling, Chapman i Hall/CRC, Boca Raton, 2003. p. 214-218.
[22] Ngow, T. S., Hassan, M. K.: Reinvestigation of Credit Default Swap Spreads Using Structural Credit Pricing Models, University of New Orleans, New Orleans, 2009., str. 15

visokog javnog i vanjskog duga, velikog fiskalnog deficita i slabog rasta, a s druge strane, prilično povoljnih strukturnih značajki. Agencija Standard & Poor's (S&P) u srpnju ove godine potvrdila je dosadašnji dugoročni kreditni rejting Hrvatske na 'BB' i kratkoročni na 'B', zadržavši negativne izglede. Moody's je još u ožujku ove godine snizio hrvatski rejting u stranoj valuti s Ba1 na Ba2, a u domaćoj s A3 na Baa1. Ključni razlozi za ovakvu akciju bili su visok javni dugi nastavak slabih izgleda gospodarskog rasta u srednjem roku. Javni dug je krajem 2015. godine bio na otprilike 86 posto BDP-a, a analitičari ove agencije procjenjuju da će do 2018. godine premašiti 90 posto.



Grafikon 2: Kretanje rejtinga Republike Hrvatske

Izvor: Hrvatska gospodarska komora, www.hgk.hr

Hrvatska trenutno s Mađarskom i Portugalom pripada grupi članica EU sa znatnim rizikom, a lošiji su tek Cipar i Grčka. U odnosu na većinu članica EU, zabrinjava niža prošla, sadašnja i buduća dinamika gospodarskog rasta, viša proračunska potrošnja i javni dug te deficit u odnosu na razinu ostvarenog BDP-a po stanovniku. Pored toga, prisutna je viša razina nezaposlenosti i niža razina izvoza te, posljedično, niži rang prema konkurentnosti i uvjetima za obavljanje poslovne aktivnosti.[23]

Drugi pokazatelj rizika zemlje koji će se analizirati na primjeru Hrvatske je CDS. Hrvatska je trenutno na visokom osmom mjestu liste država po vjerojatnosti za bankrot, sa CDS

[23]Hrvatska gospodarska komora, www.hgk.hr

rasponom od 219 bazična boda koji odražava 3,3 posto vjerojatnosti bankrota u roku od godine dana. U konkurenciji 47 zemalja čiju rizičnost prati Deutsche Bank iznad Hrvatske su Rusija, Turska, Sjeverna Afrika, Brazil, Portugal i Egipat dok je na vrhu liste ekstremno rizična Venezuela (4436 bodova). Iz grafikona 3 možemo vidjeti da se Hrvatskoj od listopada prošle godine do danas vjerojatnost bankrota smanjila s 4 posto na 3,3 posto. Najviša vrijednost vjerojatnosti bankrota bila je u studenom prošle godine i iznosila je 4,5 posto.



Grafikon 3: Godišnja vjerojatnost bankrota Hrvatske na temelju petogodišnjeg CDS-a

Izvor: Deutsche Bank Research, https://www.dbresearch.com

4. MEHANIZMI TRANSFERA RIZIKA DRŽAVE NA TROŠAK FINANCIRANJA GOSPODARSTVA

U ovom dijelu rada objasnit će se politika kamatnih stopa u bankama te interna ekonomija u bankama kao i organizacijska struktura komercijalne banke, odnosno podjela na profitne centre, troškovne centre te pseudoprofitne centre. Cilj ovog poglavlja je objasniti na koji način se rizik države transferira na trošak financiranja gospodarstva.

4.1. Politika kamatnih stopa u bankama

Društvena korist banaka je velika i manifestira se u svim segmentima. Banke angažiraju štednju, financiraju razvoj, promet, potrošnju i investicije uz vlastiti imperativ profitabilnosti, ekonomičnosti i rentabilnosti. Cilj svake banke u dužem vremenskom periodu jest aktivna pozicija na financijskom tržištu bankarskih usluga, stvaranje prepoznatljivog imena i kakvoće usluga, te ostvarenje pozitivnog financijskog rezultata uz uvećanje neto vrijednosti. Ostvarenje postavljenih ciljeva banke definiraju izabranom strategijom upravljanja.

Politika kamatnih stopa u bankama dio je politike upravljanja kreditnim potencijalom banke, koji ne može postojati bez postojanja viškova štednje. Banke stoga sudjeluju na dva cjenovno suprotstavljena tržišta, tržištu depozita na kojem je cilj najmanji trošak i tržištu zajmova na kojem je cilj najveći prihod. Na tržištu zajmova, banke kao financijski posrednici sve odluke donose temeljem informacija s tržišta.

Dostupnost u vremenu i sadržaju aktualnih informacija jedan je od preduvjeta savršenog financijskog tržišta, ponajviše tržišta depozita i kredita. Informacije značajne za investicijske odluke krasi odlika nesavršenosti.[24] Nesavršenost informacija karakteristika je složenih društvenih sustava i njihovo prirodno stanje. Uslijed toga, u bilateralnom ili multilateralnom tržišnom odnosu pojedinci će dominirati sukladno informacijskim prednostima, uz

[24] Arnott, R., Greenwald, B., Stiglitz, J. E. (1994): Information and Economic Efficiency, Information Economics and Policy, 6 (1), str. 77-88.

pretpostavljene ostale identične uvjete nužne za tržišno natjecateljstvo, pa vrijedi sintagma da su informacije na tržištu među tržišnim sudionicima asimetrično raspoređene.[25]

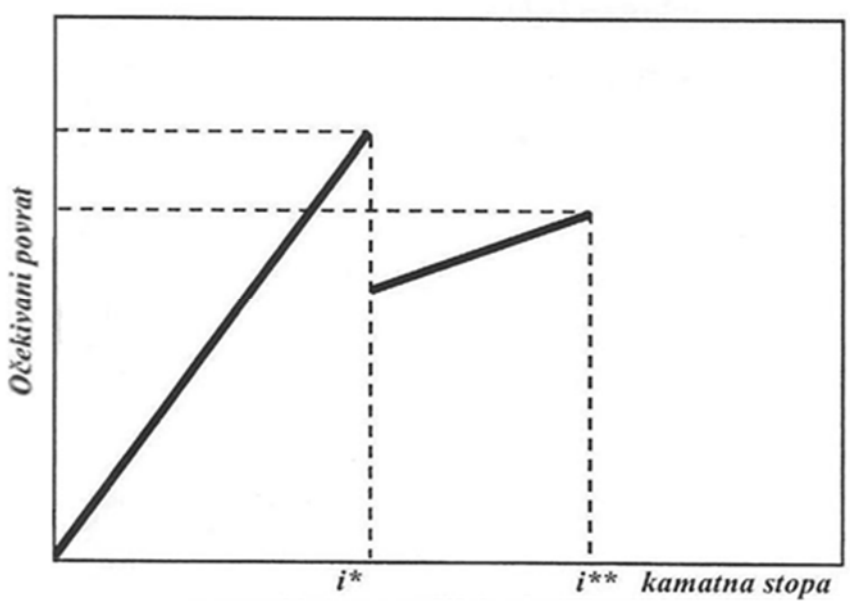
Uz pretpostavku nesavršenih tržišnih informacija i njihove asimetrične distribucije, informacija makro ili mikro prirode poslovnih odnosa, banka se stavlja u položaj anti selekcije, ili negativne selekcije, investicijskog izbora.[26] Proces analize kreditnih zahtjeva klijenata i njihove kreditne sposobnosti obuhvaća prikupljanje, analizu i selekciju svih raspoloživih odnosnih informacija. U teoriji su poznate dvije vrste distribucije informacija između tržišnih sudionika: signalna metoda i nadzor i analiza tržišnog subjekta ili tržišnog procesa.

Na osnovi nesavršenih i asimetrično distribuiranih raspoloživih informacija, stvara se tržišna ravnoteža ugovornih odnosa između sudionika tržišta. Nesavršenost informacija i složeni tržišni odnosi nakon ugovornog odnosa stvaraju preduvjete da jedna od ugovornih strana može vlastitim djelovanjem dovesti drugu u nepovoljan položaj. Ukoliko je pri tome prisutna namjera, takav se događaj u ekonomskoj teoriji naziva moralnim hazardom, koji se najbolje uočava u namjenskom korištenju kreditnih sredstava, odsustvu dobrog gospodara u upravljanju i time umanjujući kreditnu sposobnost dužnika, investicijama u projekte malih vjerojatnosti povrata, zloupotrebama u cirkulaciji novčanih tokova te drugim radnjama u neskladu s ugovornim odredbama i dobrom vjerom. I obrnuto, moralnom hazardu može biti izložen i dužnik lošim poslovanjem banke i nepoštivanjem ugovora ili nepisanih pravila u odnosu s klijentom.

U slučaju postojanja asimetrije informacija, moralnog hazarda i smanjene kreditne sposobnosti pojedinih dužnika, politika kamatnih stopa u bankama određena je njihovim stavom prema sigurnosti, ekonomičnosti i rentabilnosti poslovanja. To je sastavni dio ukupne strategije i politike banke. Dodamo li izazovu optimalne politike kamatnih stopa u bankama i njihovu valutnu i vremensku strukturu, asimetriju informacija na strani vlasnika depozita o njihovim potrebama za likvidnosti te ročnu transformaciju prikupljenih depozita problem se dodatno usložava.[27]

[25] Stiglitz, J. E., Greenwald, B. C: (1990): Asymmetric information and the new theory of the firm: Financial constraints and risk behaviour, American Economic Review, 80 (2), str. 160-165.
[26] Brennan, M., Kraus, A.: Efficient financing under asymmetric information, The Journal of Finance 42 (5), str. 1225.
[27] Pojatina, D.: Dometi bankovnog posredništva, Ekonomska misao i praksa, God XIII, br. 1, str. 75 – 94.

Politika kamatnih stopa u bankama u svojoj se cjelini upotpunjuje internom ekonomijom banke koja opće principe prilagođava pojedinačnoj strukturi. U slučaju minimalne zadovoljavajuće kreditne sposobnosti klijenata, banke će odobriti kredite s ciljem ostvarenja kamatnog prinosa uz pridružen rizik njegova ostvarenja. Uobičajeni cjenovni mehanizam uravnoteženja ponude i potražnje na tržištu kod kredita ne vrijedi. U slučaju dovoljnih sredstava banke će ograničiti kreditne plasmane (ponudu kredita), unatoč dovoljne potražnje od strane potencijalnih dužnika. Kamatna stopa kao cijena kredita koju su dužnici voljni platiti razmjerna je s rizikom investicijskih projekata. Veći kamatni rashod zahtijeva veći očekivani povrat od investicije, a time i veći rizik ulaganja. Banka će u prosjeku birati one klijente ili investicijske projekte koje je voljna financirati, sa zadovoljavajućom razinom rizika i pripadajućim prinosom.



Slika 1: Očekivani prinos i potražnja kredita[28]

Iz slike 1 možemo vidjeti da dok je na tržištu kamatna stopa do razine i* svi su potencijalni dužnici na strani tržišta potražnje za kreditom. Porastom kamatne stope na razinu i** jedan dio klijenata zadovoljavajuće kreditne sposobnosti izlazi s tržišta potražnje za kreditima. Banke tada postaju izložene izboru financiranja rizičnih klijenata, tj. njihovih investicijskih projekata.

[28] Preuzeto iz: Ercegovac, R. (2008): Politika kamatnih stopa u bankama u kontekstu rizika, doktorska disertacija, Ekonomski fakultet, Split, str. 83.

4.2. Transfer rizika države na trošak financiranja gospodarstva

Rizik zemlje se preljeva direktno na sve sudionike gospodarskog sustava preko mehanizma kamatne stope pri čemu će smjer kretanja kamatnih stopa ovisiti o kretanju rizičnosti neke zemlje. Kako je kamatna stopa trošak za korisnike posuđenih sredstava, svako povećanje kamatnih stopa potaknuto pogoršanjem kreditnog ranga zemlje poskupljuje jednako i postojeća zaduženja i nova zaduženja. Rast kamatnih stopa poslovnim subjektima dovodi do smanjenju broja projekata koji su ekonomski isplativi jer se moraju diskontirati po novoj uvećanoj diskontnoj stopi. Također, rast kamata dovodi do povećanog odljeva likvidnih sredstava iz poslovnih subjekata zbog plaćanja većih kamata. Posljedično dolazi do smanjenja investicijskog potencijala poslovnih subjekata, a u konačnici dolazi do smanjenje konkurentnosti cjelokupnog gospodarstva jedne zemlje.[29]

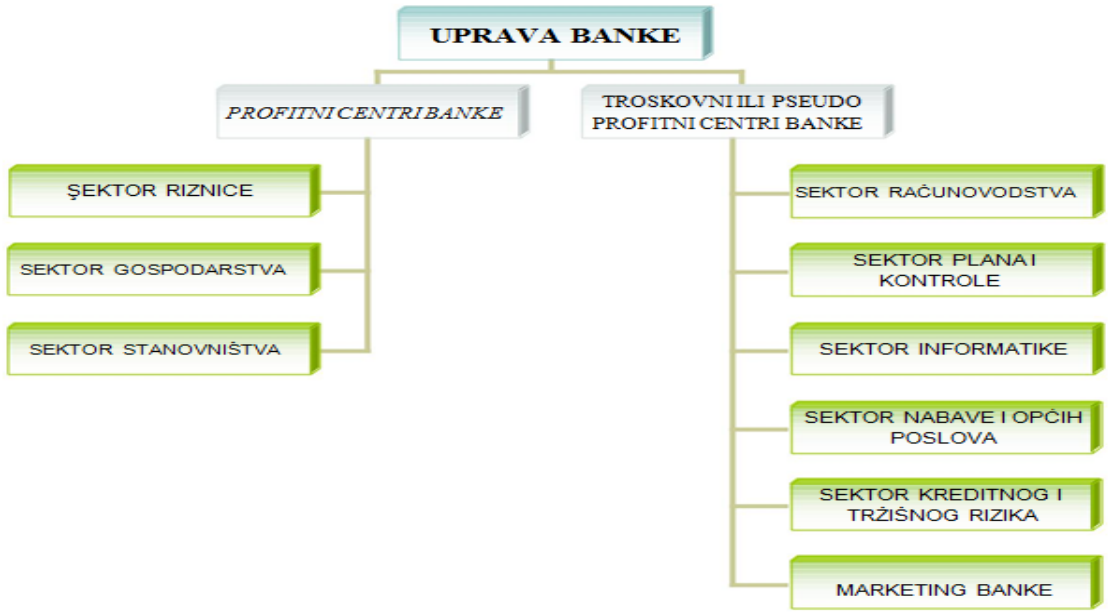
Veća kamatna stopa može dovesti do rasta inflacije i nezaposlenosti gospodarstva zemlje u kojoj kamate rastu. Veći kamate uzrokuju smanjenje profita poslovnih subjekata koji koriste financijsku polugu.[30]

Rizik zemlje može utjecati na visinu kamatnih stopa jer se on nalazi u funkciji kamatne stope kao kreditni rizik. Na rizik zemlje poslovni subjekti ne mogu utjecati, ali za njih to može obaviti država. Takvim ponašanjem država će olakšati pristup domaćih poslovnih subjekata domaćem i međunarodnom tržištu kapitala što će u konačnici rezultirati većim ekonomskim razvojem države.[31]

Interna ekonomija poduzeća događa segmentiranjem njegovih organizacijskih dijelova u profitne centre koji dezintegriraju upravljačku strukturu s ciljem veće efikasnosti, ekonomičnosti i rentabilnosti. Profitni centri jesu interni organizacijski dijelovi poduzeća gdje se zadaje, mjeri i kontrolira ostvaren profit kao pridruženi dio ukupnog profita poduzeća u odnosima između samih organizacijskih dijelova te organizacijskih dijelova i eksternog tržišta. Postojanje međuorganizacijskih odnosa prometa, razmjene i mjere uspjeha pretpostavka je postojanja interne ekonomije poduzeća.[32]

[29] Čuvalo, A. (2010): Značaj rizika države u strukturi troška financiranja gospodarstva republike Hrvatske, Ekonomski fakultet, Split, str. 58.
[30] Veselica, V. (2002): Kamatna i profitna stopa, Ekonomski pregled, 53 (7-8), str. str.610, [Internet], raspoloživo na: http://hrcak.srce.hr/28364, [06.07.2016.].
[31] Čuvalo, A.: op. cit., str. 58.
[32] Ercegovac, R.: op. cit., str. 83.

Profitni centri mogu biti ekonomski zavisni ili nezavisni. Kod ekonomski zavisnih centara prisutni su transferi među njima, dok ih kod ekonomski nezavisnih centara nema. Razlikuju se dvije vrste referentnih transfernih cijena, troškovno i tržišno temeljene. Koji pristup ćemo izabrati, ovisi o ciljnoj vrijednosti profita sektora riznice. Troškovni pristup strukture međusektorskih internih transfernih cijena izabire se ukoliko je pretpostavka da je ciljni profit sektora riznice nula. U ovom slučaju, sektor riznice nije primarno profitabilan sektor, već mu se profit podređuje ostalim profitabilnim centrima i banci u cjelini. Tržišni pristup strukture međusektorskih internih transfernih cijena kod pretpostavke da sektor riznice u okviru interne ekonomije djeluje samostalno, a profit mu nije podređen primarnoj funkciji upravljanja likvidnosti banke za razliku od troškovnog pristupa. Tržišni pristup također i potiče natjecateljstvo između profitnih centara, a ciljevi i politike kamatnih stopa usmjeravaju se prema tržišnoj realnosti.



Slika 2: Organizacijska struktura komercijalne banke[33]

Na slici 2 možemo vidjeti organizacijsku strukturu komercijalne banke. Na vrhu ove strukture je uprava banke koja se dijeli s jedne strane na profitne centre banke, a s druge strane na troškovne ili pseudoprofitne centre banke. U profitnim centrima se zadaje, mjeri i kontrolira

[33] Preuzeto iz: Ercegovac, R.: op. cit., str. 83.

ostvaren profit kao pridruženi dio ukupnog profita poduzeća, kako između samih organizacijskih dijelova, tako i između organizacijskih dijelova i eksternog tržišta. Unutar profitnih centara banke razlikuju se sektor riznice, sektor gospodarstva i sektor stanovništva. S druge strane su troškovni centri, čiji je temeljni cilj uspješno upravljanje troškovima i njihova racionalizacija u procesu proizvodnje. Dok pseudoprofitni centri koji bilježe profit samo u interno postavljenim obračunima transakcija, temeljem iskustvenih ili normativa te tržišnim troškom. Troškovni ili pseudoprofitni centri banke dijele se na sektor računovodstva, sektor plana i kontrole, sektor informatike, sektor nabave i općih poslova, sektor kreditnog i tržišnog rizika te marketing banke.

Temeljna djelatnost banke je mobilizacija neuposlene štednje i njezino alociranje za financiranje privrednih deficita, a interna ekonomija profitnih centara realizira se kroz kamatu, odnosno cijenu, po kojoj se fondovi posuđuju i uzajmljuju.

Interne transferne cijene su mehanizam upravljanja strukturom imovine i obveza te profitom svakog profitnog centra, ali i banke u cjelini. Teorija definira interne transferne cijene kao mehanizam obračuna prihoda na razini interne organizacijske jedinice, pojedinačnog proizvoda ili neke druge izabrane svrhovite upravljane kategorije. Shvatimo li banku kao instituciju u transferu štednje između sposobnosti i potreba za financiranjem među stožerima društvene reprodukcije u totalu financijskog sustava, interne transferne cijene određuju najveći trošak izvora i najmanji prihod plasmana kao graničnu vrijednost dokle će banka zadržati konkurentnost uz ostvarivanje očekivanog prihoda. U procesima pozajmljivanja i uzajmljivanja banka stvara financijske imovine, a proces financijskog posredništva definira joj i karakter proizvodne funkcije u stvaranju nove vrijednosti u gospodarstvu. Pri tome svaki pojedinačni profitni centar ima drugačiju ulogu i odgovornost u proizvodnom procesu banke.[34]

[34] Ercegovac, R.: op. cit., str. 85.

5. ANALIZA UTJECAJA RIZIKA DRŽAVE NA TROŠAK FINANCIRANJA HRVATSKIH PODUZEĆA

Kako bi se utvrdio utjecaj rizika države na trošak financiranja hrvatskih poduzeća, provest će se korelacijska i regresijska analiza. Pritom će se kao mjere troška koristiti kamatne stope na devizne kredite stanovništvu i gospodarstvu. Također, analizirat će se kretanje CDS-a te kamatna stopa u eurozoni (tromjesečni Euribor) za razdoblje 31.10.2008-30.06.2016. Svi korišteni podaci nalaze se u prilogu 1.

Kako je ranije spomenuto, CDS (*Credit Default Swap*) predstavlja ugovor o financijskom derivatu između dvije zainteresirane strane i uobičajeno se može odnositi na zajam ili obveznicu, a koristi se kao mjera rizičnosti zemlje, odnosno premija za rizik.[35] Jednogodišnji CDS predstavlja premiju rizika hrvatske državne obveznice s rokom dospijeća od jedne godine, a petogodišnji CDS s rokom dospijeća od pet godina. U radu će se koristiti CDS u valuti Europske Unije.

Euribor (*Euro Interbank Offered Rate*) je referentna kamatna stopa za europsko novčano tržište, a utvrđuje se od strane Europske bankarske unije koju predstavlja 2.800 banaka u 15 država članica Europske unije i EMU sektor ACI-ja, Financial Markets Association. Reprezentativni uzorak sastavljen od vodećih banaka dostavlja dnevne kotacije za trinaest dospijeća od jednog tjedna (1W) do jedne godine (1Y), po kojima se međubankarski oročeni depoziti denominirani u EUR-u posuđuju između vodećih banaka euro zone.[36]

U tablici 2 prikazana je deskriptivna statistika spomenutih varijabli.

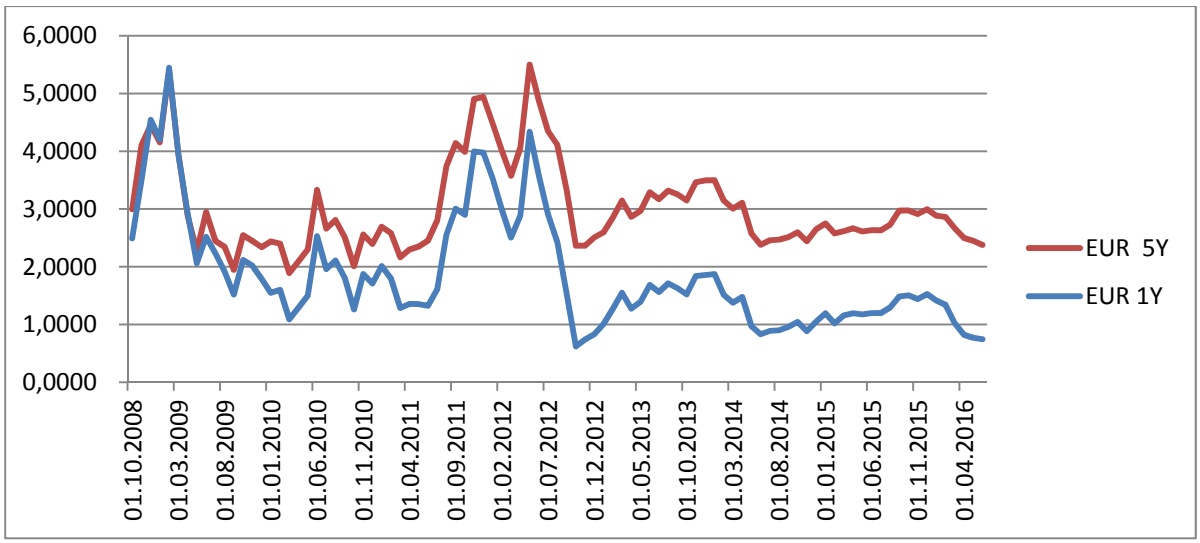
[35]Hypo Alpe Adria Bank: Metodologija promjene kamatnih stopa u kreditnom i depozitnom poslovanju s potrošačima Hypo Alpe-Adria-Bank d.d, str. 4, [Internet], raspoloživo na: http://www.hypo-alpe-adria.hr/sites/hypo-alpe-adria.hr/files/content/metodologija_promjene_kamatnih_stopa_09012013.pdf, [15.07.2016.].
[36]Hypo Alpe Adria Bank: op. cit., str. 6.

Tablica 2: Deskriptivna statistika varijabli

	N	Minimum	Maksimum	Aritmetička sredina	Standardna devijacija
CDS - EUR 1Y	93	,622	5,446	1,862	,980
CDS - EUR 5Y	93	1,890	5,499	3,015	,782
EURIBOR 3M	93	-,2860	4,760	,664	,819
Kamatne stope na devizne kredite stanovništvu	93	4,460	8,450	6,667	1,286
Kamatne stope na devizne kredite gospodarstvu	93	4,210	8,500	6,191	1,105

Izvor: Izračun autora; Reuters i HNB

Na grafikonu 4 prikazano je kretanje jednogodišnjeg i petogodišnjeg CDS-a Hrvatske za razdoblje 31.10.2008.-30.06.2016. Na temelju njega i podataka iz ranije tablice može se vidjeti da CDS sa dospijećem od pet godina ima konzistentno više vrijednosti u promatranom razdoblju, pri čemu njegova aritmetička sredina iznosi 3,015. CDS sa dospijećem plaćanja od jedne godine ima niže vrijednosti, s aritmetičkom sredinom od 1,862. Kako bi se utvrdila statistička značajnost razlike proveden je t-test za nezavisne uzorke. Prvo je provjerena sličnost varijanci upotrebom F-testa, koji je pokazao da razlike nisu statistički značajne (F-test = 0,032). T-test je pokazao da su razlike među ove dvije varijable statistički značajne pri 1% rizika.



Grafikon 4: Kretanje jednogodišnjeg i petogodišnjeg CDS-a Hrvatske za razdoblje 31.10.2008.-30.06.2016.

Izvor: Izrada autora; Reuters

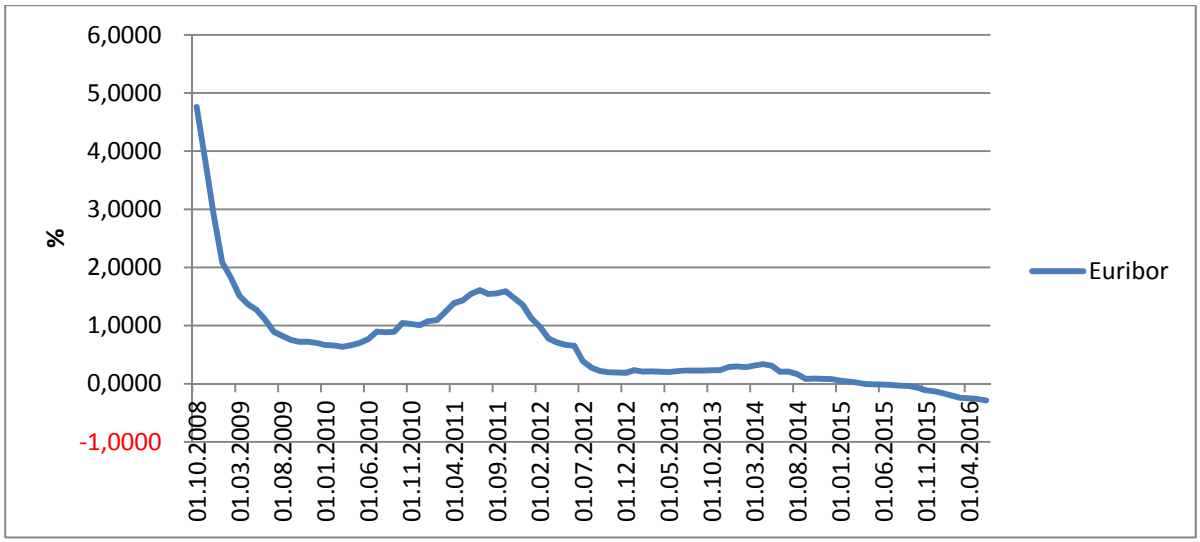
S obzirom na sličnost njihovog variranja uočenu iz grafikona, provedena je korelacijska analiza tih dviju varijabli, čiji su rezultati prikazani u tablici 3. Kako je vidljivo, Pearsonov koeficijent korelacije iznosi 0,855, što znači da postoji jaka pozitivna povezanost između kretanja vrijednosti ovih dviju varijabli, koja je statistički značajna i uz 1% rizika.

Tablica 3: Korelacijska matrica - povezanost jednogodišnjeg i petogodišnjeg CDS-a u razdoblju 31.10.2008.-30.06.2016.

		CDS - EUR 1Y	CDS - EUR 5Y
CDS - EUR 1Y	Pearson Correlation	1	,855
	Sig. (2-tailed)		,000
	N	93	93
CDS - EUR 5Y	Pearson Correlation	,855	1
	Sig. (2-tailed)	,000	
	N	93	93

Izvor: Izračun autora; Reuters

Grafikon 5 prikazuje kretanje Euribora u istom razdoblju, te možemo vidjeti da njezine vrijednosti opadaju, te je vrijednost na početku perioda iznosila 4,760%, a na kraju -0,286%.



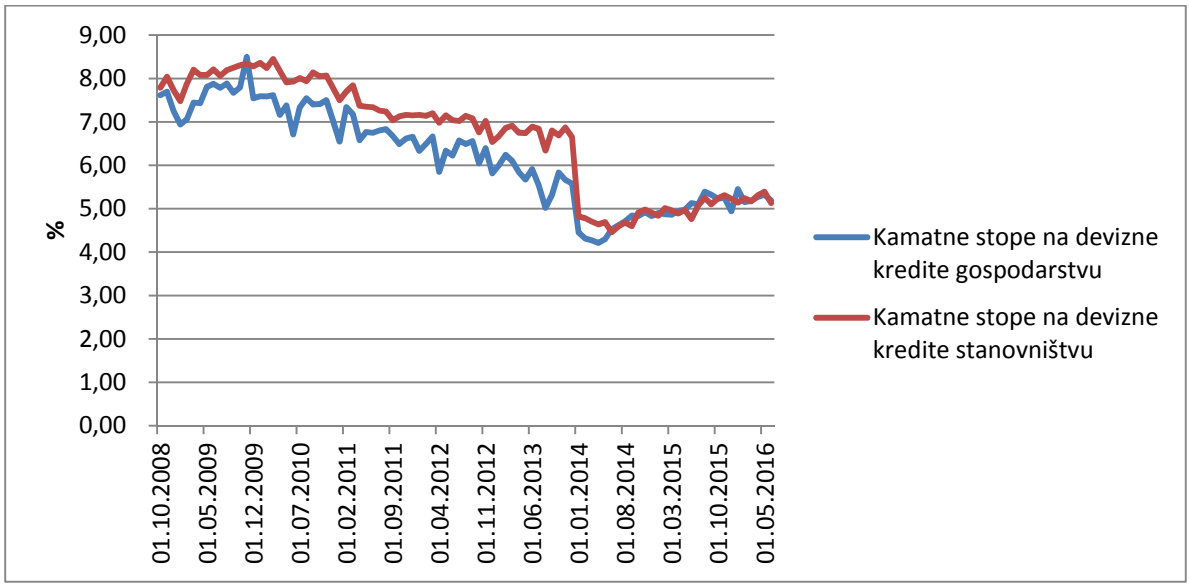
Grafikon 5: Kretanje Euribor stope za razdoblje 31.10.2008.-30.06.2016.

Izvor: Izrada autora; Reuters

Pri formiranju kamatnih stopa za devizne kredite koriste se vrijednosti oba do sad objašnjena parametra – kreditni rizik (CDS) te referentna kamatna stopa Euribor.

Grafikon 6 prikazuje kretanje kamatnih stopa za devizne kredite gospodarstvu i stanovništvu tijekom spomenutog perioda. Vidljivo je da razine kamatnih stopa, uz određene varijacije, polako opadaju od 2009. godine do kraja 2013., nakon čega u siječnju 2014. dolazi do drastičnog pada njihovih vrijednosti. Od tog perioda, obje stope nastavljaju polako rasti.

F-test vrijednosti 0,144 pokazuje da nema statistički značajne razlike u varijancama ovih varijabli, radi čega je proveden t-test, koji pokazuje da kamatne stope na devizne kredite stanovništvu imaju statistički značajno veću aritmetičku sredinu od stopa za gospodarstvo uz razinu rizika od 1%.



Grafikon 6: **Kretanje kamatne stope za devizne kredite u gospodarstvu i stanovništvu u razdoblju 31.10.2008.-30.06.2016.**

Izvor: Izrada autora; HNB

Iz grafikona se može uočiti sličnost u variranju stopa, radi čega je ponovo provedena korelacijska analiza, čiji su rezultati u tablici 4. Povezanost ovih dviju varijabli iznosi čak 0,955, te je statistički značajna pri razini rizika od 1%.

Tablica 4: Korelacijska matrica - povezanost kamatnih stopa za devizne kredite stanovništvu i gospodarstvu u razdoblju 31.10.2008.-30.06.2016.

		kam_stope_stanovnistvu	kam_stope_gospodarstvu
Kamatne stope na devizne kredite stanovništvu	Pearson Correlation	1	,955
	Sig. (2-tailed)		,000
	N	93	93
Kamatne stope na devizne kredite gospodarstvu	Pearson Correlation	,955	1
	Sig. (2-tailed)	,000	
	N	93	93

Izvor: Izračun autora; HNB

Napravljena je korelacijska analiza svih promatranih varijabli, čiji su rezultati prikazani u tablici 7. Vidljivo je da su korelacije svih varijabli pozitivne i barem umjereno visoke te značajne na razini α = 1%. Najvišu međusobnu povezanost imaju varijable kamatnih stopa na devizne kredite (r = 0,955), što je ranije spomenuto. Povezanost stope Euribora s kamatnom stopom na devizne kredite stanovništvu iznosi 0,596, a gospodarstvu 0,626, što predstavlja umjerenu do dobru povezanost. Korelacija rizika zemlje sa kamatnom stopom na devizne kredite stanovništvu iznosi 0,481, a gospodarstvu 0,453, što se može smatrati relativno slabom do umjerenom.

Tablica 5: Korelacijska matrica varijabli

		CDS - EUR 1Y	EURIBOR 3M	kam_stope_stanovnistvu	kam_stope_gospodarstvu
CDS - EUR 1Y	Pearson Corr.	1	**,621**	**,481**	**,453**
	Sig. (2-tailed)		,000	,000	,000
	N	93	93	93	93
EURIBOR 3M	Pearson Corr.	**,621**	1	**,596**	**,626**
	Sig. (2-tailed)	,000		,000	,000
	N	93	93	93	93
Kamatne stope na devizne kredite stanovništvu	Pearson Corr.	**,481**	**,596**	1	**,955**
	Sig. (2-tailed)	,000	,000		,000
	N	93	93	93	93
Kamatne stope na devizne kredite gospodarstvu	Pearson Corr.	**,453**	**,626**	**,955**	1
	Sig. (2-tailed)	,000	,000	,000	
	N	93	93	93	93

Izvor: Izračun autora; Reuters i HNB

Regresijska analiza je statistička metoda koja se bavi opisivanjem ovisnosti određene varijable o jednoj ili više drugih varijabli. Pritom se varijabla čije se varijacije objašnjavaju pomoću varijacija drugih varijabli naziva zavisnom (regresand) varijablom, a varijable kojima se objašnjavaju varijacije zavisne varijable nazivaju se nezavisnim (regresorskim) varijablama.

Postupak regresijske analize započinje prikupljanjem podataka o pojavama tijekom određenog vremena, nakon čega se u grafikonu ucrtavaju parovi vrijednosti pojava za određeni vremenski interval, na način da se vrijednost nezavisne varijable mjeri po vodoravnoj (x) osi, a nezavisne varijable po okomitoj osi (y) grafikona. Ovaj se grafikon naziva dijagramom raspršenja (rasipanja). Postoji li približno linearan odnos među pojavama, ucrtava se pravac čija jednadžba glasi:

$$Y = a + bX \quad (1)$$

Pri čemu je:

a - odsječak na osi y; parametar daje procijenjenu vrijednost Y za X=0,

b - koeficijent nagiba pravca; parametar daje procjenu povećanja ili smanjenja u Y koje je posljedica svakog pojedinog povećanja ili smanjenja u X,

Y – zavisna varijabla,

X – nezavisna varijabla.

Kad postoji samo jedna nezavisna varijabla, riječ je o jednostavnoj regresijskoj analizi. S druge strane, u modelu višestruke regresije, jedna zavisna varijabla ovisi o više nezavisnih. Taj se model koristi u ovom radu, te se kao regresorske varijable koriste premija kreditnog rizika Republike Hrvatske te Europska međubankarska kamatna stopa Euribor. Provedene su dvije regresijske analize, u kojima su kao zavisne varijable postavljene kamatne stope na devizne kredite stanovništvu i gospodarstvu.

Za slučaj kamatne stope na devizne kredite stanovništvu, osnovni rezultati višestruke regresijske analize prikazani su u tablici 6. Vrijednost koeficijenta multiple korelacije je R=0,613 na temelju čega možemo zaključiti da postoji dobra pozitivna povezanost varijabli u modelu. Koeficijent multiple determinacije R^2=0,376, što znači da je ocijenjenim regresijskim modelom protumačeno 37,6% sume kvadrata ukupnih odstupanja zavisne varijable od njene aritmetičke sredine.

Dijagrami rasipanja za korištene varijable prikazani su u prilozima 2 i 3.

Tablica 6: Sažetak modela regresijske analize sa kamatnom stopom na devizne kredite stanovništvu kao zavisnom varijablom.

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,613	,376	,362	1,028	,094

Izvor: Izračun autora; Reuters i HNB

Tablica 7 sadrži podatke o protumačenim, neprotumačenim i ukupnim odstupanjima ocijenjenog modela, te vrijednost F-testa s empirijskom značajnosti. Granična razina značajnosti (α), prikazana u tablici 6, a koja iznosi $\alpha \approx 0$, pokazuje da je ovaj regresijski model statistički značajan uz razinu rizika manju i od 1%.

Tablica 7: Tablica ANOVA ocijenjenog regresijskog modela s kamatnom stopom na devizne kredite stanovništvu kao zavisnom varijablom.

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	57,179	2	28,589	27,062	,000
	Residual	95,080	90	1,056		
	Total	152,259	92			

Izvor: Izračun autora; Reuters i HNB

Tablica 8 prikazuje vrijednosti ocijenjenih parametara, njihove standardne greške i t-omjere te se na temelju tih podataka može zapisati analitički izraz modela koji izgleda ovako:

$$Y = 5{,}722 + 0{,}236\, X_1 + \ 0{,}762\, X_2 \qquad (2)$$

Pri čemu je:

Y – zavisna varijabla, kamatna stopa na devizne kredite stanovništvu

X_1 – prva nezavisna varijabla, jednogodišnji CDS

X_2 - druga nezavisna varijabla, tromjesečni Euribor

Iz navedene jednadžbe slijede interpretacije procijenjenih parametara. Prvi regresijski koeficijent, $\beta_1 = 0{,}236$ znači da ako se rizik zemlje poveća za 1%, a Euribor ostane nepromijenjen, kamatna će se stopa na devizne kredite stanovništvu povećati za 0,236%. Slično tome, ako CDS ostane nepromijenjen, a vrijednost Euribora poraste za 1%, povećat će se kamatna stopa na devizne kredite stanovništvu za 0,762%.

Tablica 8: Koeficijenti linearnog regresijskog modela s kamatnom stopom na devizne kredite stanovništvu kao zavisnom varijablom.

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Collinearity Statistics	
		B	Std. Error	Beta			Tolerance	VIF
1	(Constant)	5,722	,235		24,327	,000		
	CDS_1Y_EUR	,236	,139	,180	1,690	,095	,614	1,628
	EURIBOR_3M	,762	,167	,485	4,563	,000	,614	1,628

Izvor: Izračun autora; Reuters i HNB

U tablici 8 navedene su i vrijednosti t-testa za svaku varijablu te procjene njihove značajnosti. Analizom podataka može se zaključiti da je varijabla rizika zemlje (CNS) značajna tek na razini 9,5%, dok je stopa Euribora značajna uz rizik manji od 1%. Drugim riječima, promjene u obje varijable imaju utjecaj na promjene kamatnih stopa na devizne kredite stanovništvu na razini značajnosti od 10%.

Također, iz iste se tablice može dobiti i potvrda o nepostojanju problema multikolinearnosti regresorskih varijabli pošto su za oba parametra regresije faktori inflacije varijance (VIF) manji od 5, a postotak tolerancije veći od 20%.

Za slučaj kamatne stope na devizne kredite gospodarstvu, osnovni rezultati višestruke regresijske analize prikazani su u tablici 9. Vrijednost koeficijenta multiple korelacije iznosi R=0,631 na temelju čega možemo zaključiti da postoji dobra pozitivna povezanost varijabli u modelu. Koeficijent multiple determinacije R^2=0,398, što znači da je ocijenjenim regresijskim modelom protumačeno 39,8% sume kvadrata ukupnih odstupanja zavisne varijable.

Dijagram rasipanja za korištene varijable prikazani su u prilozima 4 i 5.

Tablica 9: Sažetak modela regresijske analize sa kamatnom stopom na devizne kredite gospodarstvu kao zavisnom varijablom

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,631	,398	,385	,867	,172

Izvor: Izračun autora; Reuters i HNB

Na temelju podataka iz tablice 10 može se zaključiti da je i ovaj regresijski model statistički značajan uz razinu rizika manju i od 1%.

Tablica 10: Tablica ANOVA ocijenjenog regresijskog modela s kamatnom stopom na devizne kredite gospodarstvu kao zavisnom varijablom.

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	44,782	2	22,391	29,805	,000
	Residual	67,612	90	,751		
	Total	112,394	92			

Izvor: Izračun autora; Reuters i HNB

Koristeći parametre iz tablice 11, analitički izraz modela izgleda ovako:

$$Y = 5{,}469 + 0{,}117\,X_1 + 0{,}757\,X_2 \quad (3)$$

Pri čemu je:

Y – zavisna varijabla, kamatna stopa na devizne kredite gospodarstvu

X_1 – prva nezavisna varijabla, CDS - EUR 1Y

X_2 - druga nezavisna varijabla, Euribor

Parametre interpretiramo kao i u slučaju ranijeg modela. Dakle, poveća li se rizik zemlje poveća za 1%, a Euribor ostane nepromijenjen, kamatna će se stopa na devizne kredite stanovništvu povećati za 0,117%. Ostane li CDS nepromijenjen, a vrijednost Euribora poraste za 1%, povećat će se kamatna stopa na devizne kredite stanovništvu za 0,757%.

Tablica 11: Koeficijenti linearnog regresijskog modela s kamatnom stopom na devizne kredite gospodarstvu kao zavisnom varijablom.

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Collinearity Statistics	
		B	Std. Error	Beta			Tolerance	VIF
1	(Constant)	5,469	,198		27,569	,000		
	CDS_1Y_EUR	,117	,118	,104	,999	,320	,614	1,628
	EURIBOR_3M	,757	,141	,561	5,381	,000	,614	1,628

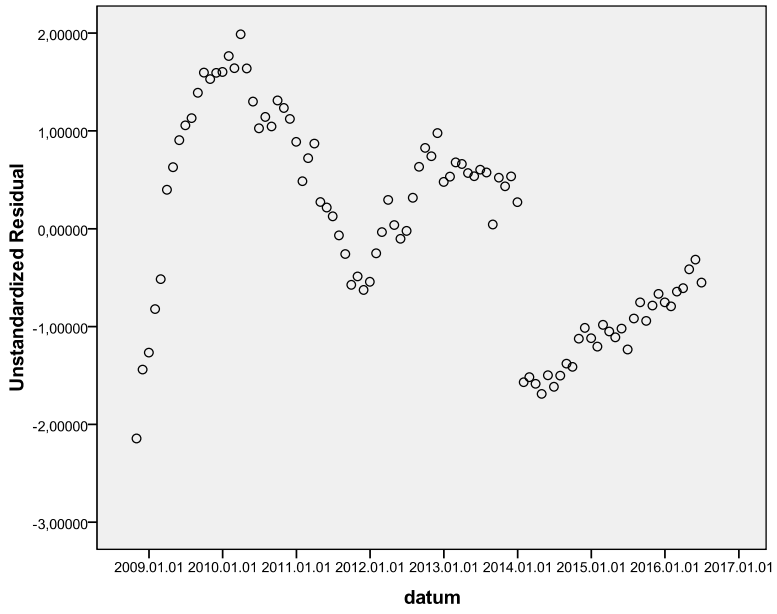
Izvor: Izračun autora; Reuters i HNB

Analiza rezultata t-testova pokazuje da je varijabla rizika zemlje značajna tek na razini od 32%, te se stoga ne može smatrati dobrim prediktorom promjene kamatnih stopa na devizne kredite gospodarstvu. S druge strane, stopa Euribora značajna je na razini manjoj od 1% te se time pokazuje kao dobar prediktor zavisnoj varijabli.

Ni u ovom slučaju nema problema multikolinearnosti regresorskih varijabli, pošto su za oba parametra regresije faktori inflacije varijance manji od 5, a postotak tolerancije veći od 20%, kao što je vidljivo iz tablice.

Jedna od polaznih pretpostavki modela višestruke regresije odnosi se na međusobnu nepovezanost slučajnih varijabli, tj. rezidualni ne smiju međusobno korelirati. Za testiranje postojanja problema autokorelacije reziduala koristio se Durbin-Watsonov (DW) test. Dobivena empirijska test veličina uspoređuje se s kritičnim vrijednostima d_l i d_u koje se za zadanu razinu značajnosti (α), veličinu uzorka (n), i broj regresorskih varijabli (k) očitavaju iz tablica za Durbin-Watsonov test. Ukoliko je dobivena empirijska vrijednost blizu 2, u modelu ne postoji problem autokorelacije reziduala. Vrijednost blizu 0 upućuje na pozitivnu autokorelaciju, dok vrijednost blizu 4 upućuje na negativnu autokorelaciju reziduala. Kako je vidljivo iz tablice 5 prve regresijske analize, vrijednost DW testa iznosi 0,094, što upućuje na postojanje visokog stupnja autokorelacije.

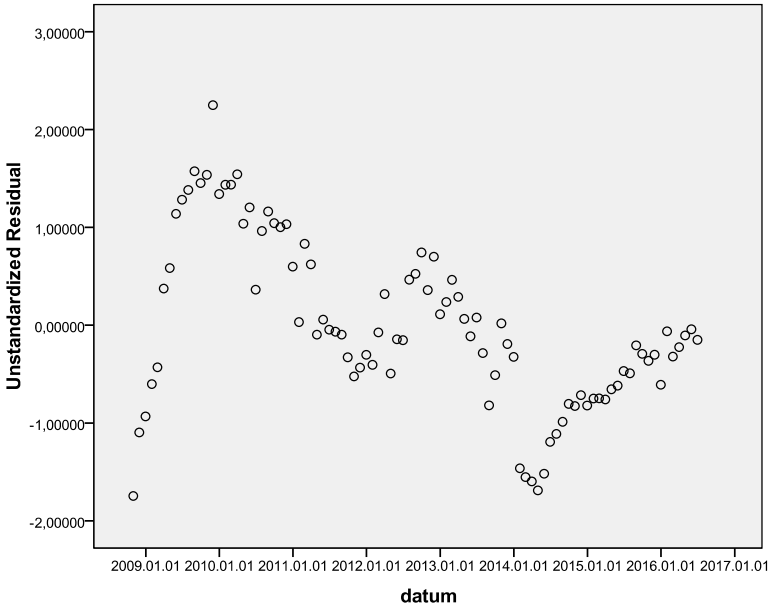
Na grafikonu 6 prikazano je rasipanje reziduala, te se iz njega jasno može vidjeti da ono nije slučajno, kao što bi prema postavkama modela trebalo biti.



Grafikon 7: Dijagram rasipanja reziduala

Izvor: Izrada autora; Reuters i HNB

Za slučaj kamatne stope na devizne kredite gospodarstvu, kako je vidljivo iz tablice 8, vrijednost DW testa iznosi 0,172, što upućuje na postojanje visokog stupnja autokorelacije. Na grafikonu 6 prikazano je rasipanje reziduala za drugu regresijsku analizu.



Grafikon 8: Dijagram rasipanja reziduala

Izvor: Izrada autora; Reuters i HNB

6. OČEKIVANJE KRETANJA RIZIKA DRŽAVE U ODNOSU NA REALNE I FINANCIJSKE PARAMETRE GOSPODARSTVA

Na visinu rizika države posredno i neposredno djeluje više faktora. S obzirom na to da bi kamatni rasponi trebali reflektirati razinu kreditnog rizika zemlje, za očekivati je da makroekonomski fundamenti određuju njihovu dinamiku putem utjecaja na pripadnu vjerojatnost neispunjavanja obveza izdavatelja obveznice.[37] Osim njih, na kretanje kamatnih raspona utječu i ostali elementi, poput sklonost riziku ili prelijevanja financijskih šokova među zemljama. U nastavku će se obraditi neki parametri gospodarstva, kao i njihovo pretpostavljeno buduće kretanje, ne bi li se izvele pretpostavke o budućem kretanju rizika države.

Godišnja stopa rasta BDP-a 2014. godine iznosila je -0,4, 2015. 1,6, dok se za 2016. godinu procjenjuje vrijednost od 2,3, kao što je vidljivo u tablici 12 i na slici 3. Povećanje stope BDP-a negativno je povezano s procjenama rizika zemlje pa bi se on mogao smanjiti nastavi li se povećanje stope. Analitičari Ekonomskog instituta u Zagrebu na temelju podataka iz prve polovice ove godine te dostupnih indikatora za treće tromjesečje, najavljuju stopu rasta BDP-a od 2,6% u 2016. godini te ubrzavanje rasta od 2,7% u 2017. godini.[38]

Prema procjenama stručnjaka ESB-a za europodručje, na godišnjoj bi razini BDP trebao porasti za 1,7 % u 2016. te 1,6 % u 2017. i 2018. godini.[39]

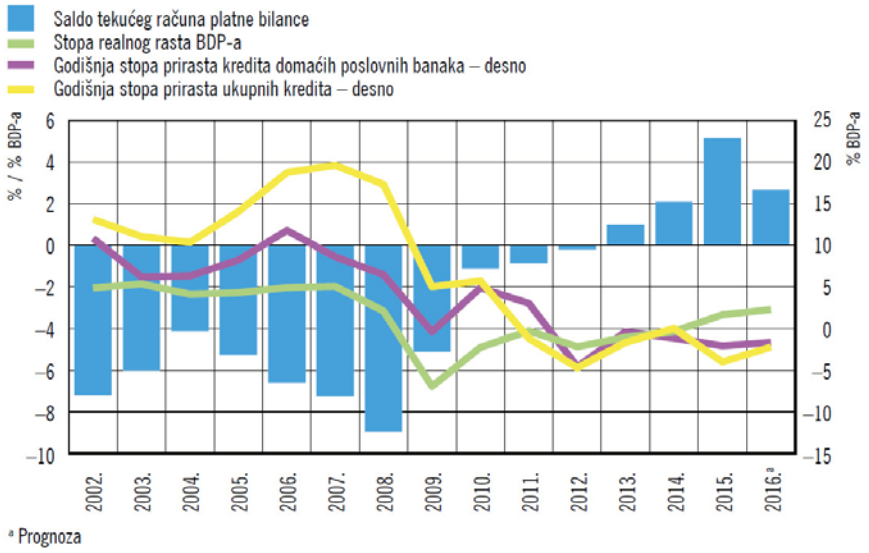
[37] Kunovac, D. (2013): Trošak zaduživanja odabranih zemalja Europske unije i Hrvatske–uloga prelijevanja vanjskih šokova, HNB, Zagreb, str 1.
[38] Ekonomski institut Zagreb (2016): Priopćenje za javnost povodom objavljivanja novog broja publikacije Croatian Economic Outlook Quaterly, [Internet], raspoloživo na: www.eizg.hr/Download.ashx?FileID=ec66fef2-e76a-4524-9f25-8be632770f49 [21.09.2016.].
[39] Europska središnja banka (2016): Makroekonomske projekcije stručnjaka ESB-a za europodručje, rujan 2016, str. 2, [Internet], raspoloživo na: https://www.ecb.europa.eu/pub/pdf/other/ecbstaffprojections201609.hr.pdf?3b923937f422b86e6bb049ad1391e0d3, [21.09.2016.].

Tablica 12: Kretanje nekih makroekonomskih parametara u 2014. i 2015. godini sa procjenama za 2016.

	2014.	2015.	2016.
Godišnja stopa rasta BDP-a	-0,4	1,6	2,3
Fiskalna bilanca, % BDP-a	-5,5	-3,2	-2,3
Bilanca tekućeg računa, % BDP-a	2,1	5,1	2,7
Javni dug, % BDP-a	85,1	86,7	87
Inozemni dug, % BDP-a	105,6	108,4	103,7

Izvor: Izrada autora prema HNB (2016): Financijska stabilnost, (17), str. 8-9, [Internet], raspoloživo na: https://www.hnb.hr/documents/20182/521139/h-fs-17-2016.pdf/c4a6a955-54f8-439e-87fe-2f278612b0cd, [21.09.2016.].

Količina javnog i inozemnog duga pozitivno je povezana sa procjenama rizičnosti države. Iz podataka u tablici 8 možemo primijetiti da je udio javnog duga u BDP-u izuzetno visok te se procjenjuje njegov porast na 87%. Za udio inozemnog duga u BDP-u procjenjuje se smanjivanje u 2016. godini, sa 108,4% na 103,7%, dok bi se do kraja godine mogao spustiti na oko 96,9% radi očekivanog porasta nominalnog BDP-a i nastavka razduživanja kreditnih institucija.[40]



Slika 3: Kretanje salda tekućeg računa platne bilance, stope realnog rasta BDP-a te godišnjih stopa prirasta kredita domaćih poslovnih banaka i ukupnih kredita

Izvor: HNB (2016): Financijska stabilnost, (17), str. 12, [Internet], raspoloživo na: https://www.hnb.hr/documents/20182/521139/h-fs-17-2016.pdf/c4a6a955-54f8-439e-87fe-2f278612b0cd, [21.09.2016.].

[40] HNB (2016): Financijska stabilnost, (17), str. 14, [Internet], raspoloživo na: https://www.hnb.hr/documents/20182/521139/h-fs-17-2016.pdf/c4a6a955-54f8-439e-87fe-2f278612b0cd, [21.09.2016.].

Prema procjenama stručnjaka ESB-a za europodručje, stope tromjesečnog Euribora iznosit će -0,4 % u 2017. i 2018. godini, te se pretpostavlja da će to imati učinak na smanjenje kamatnih stopa.[41] S obzirom na pozitivnu povezanost kamatnih stopa i procjena rizike države, može se pretpostaviti da će doći i do smanjenja procjene rizika zemlje.

Tablica 13. Procjene kretanja Euribora 10.2017.-10.2018.

Datum	Maksimalan	Minimalan	Prosječan
10.2016.	-0.046	-0.060	-0.052
11.2016.	-0.044	-0.050	-0.048
12.2016.	-0.046	-0.052	-0.049
01.2017.	-0.044	-0.050	-0.048
02.2017.	-0.046	-0.052	-0.049
03.2017.	-0.048	-0.054	-0.051
04.2017.	-0.051	-0.057	-0.053
05.2017.	-0.048	-0.054	-0.052
06.2017.	-0.045	-0.051	-0.049
07.2017.	-0.043	-0.049	-0.047
08.2017.	-0.045	-0.051	-0.048
09.2017.	-0.043	-0.049	-0.047
10.2017.	-0.041	-0.047	-0.045
11.2017.	-0.039	-0.045	-0.042
12.2017.	-0.038	-0.042	-0.041
01.2018.	-0.039	-0.043	-0.041
02.2018.	-0.039	-0.045	-0.042
03.2018.	-0.038	-0.042	-0.041
04.2018.	-0.036	-0.040	-0.039
05.2018.	-0.034	-0.038	-0.037
06.2018.	-0.032	-0.036	-0.035
07.2018.	-0.030	-0.034	-0.033
08.2018.	-0.029	-0.033	-0.031
09.2018.	-0.028	-0.032	-0.030
10.2018.	-0.028	-0.032	-0.030

Izvor: The Economy Forecast Agency, http://longforecast.com/euribor/euribor-forecast-for-2015-2016-and-2017.html

[41] HNB: op. cit., 14,

Stope inflacije također utječu na procjenu rizika zemlje, pri čemu se procjena rizičnosti povećava u očekivanju inflacije. U sljedećem razdoblju, kao rezultat oporavka cijena sirovina na svjetskom tržištu i nastavka rasta domaće potrošnje, prema procjenama Ministarstva financija, očekuje se ubrzanje stope inflacije na 1,4% u 2017. te 1,6% u 2018. godini.[42]

Na razini europodručja, očekuje se da će inflacija mjerena harmoniziranim indeksom potrošačkih cijena (HIPC), u 2016. iznositi prosječno 0,2 %, dok bi u 2017. godini inflacija mjerena HIPC-om trebala porasti na 1,2 %. Očekuje se da gospodarski oporavak koji je u tijeku i smanjenje gospodarskog pada utječu na postupno povećanje inflacije mjerene HIPC-om bez energije i prehrambenih proizvoda tijekom projekcijskog razdoblja, zbog čega bi se ukupna inflacija trebala dodatno povećati na 1,6 % u 2018.[43]

Ranije je spomenuto da su rejting agencije S&P i Moody´s zadržale ocjenu podinvesticijskog ranga za Hrvatsku. Sve tri vodeće kreditne agencije smatraju da zbog loših izgleda za gospodarski rast, brzorastućeg i visokog javnog duga i velikih proračunskih deficita, postoji znatan rizik za ulaganja, a izglede, koji predstavljaju očekivanja daljnjih kretanja, ocjenjuju negativnima.[44] Ovako loš kreditni rejting negativno utječe na procjene rizika zemlje.

[42] Ministarstvo financija (2016): Smjernice za izradu DP RH za 2016 i projekcija za 2017 i 2018, Ministarstvo financija, Zagreb, str. 7, [Internet], raspoloživo na: https://vlada.gov.hr/UserDocsImages/Sjednice/2016/5%20sjednica%20Vlade/5%20-%201_novo.pdf, [21.09.2016.].
[43] Europska središnja banka: op. cit., str. 1.
[44] Hrvatska gospodarska komora, www.hgk.hr

7. ZAKLJUČAK

Razlikujemo dva pojavna oblika rizika države. Prvi pojavni oblik rizika države je sistemski rizik te se odnosi na snagu države da preko svojih institucija utječe na sve sudionike gospodarskog sustava. Ovaj pojavni oblik rizika države poslovni subjekti ne mogu izbjeći. Drugi pojavni oblik rizika zemlje odnosi se na državu kao dužnika kod emitiranja državnog duga. Ovdje se država pojavljuje u funkciji izvora nesistemskog rizika prema drugim subjektima. Pretpostavlja se da država funkcionira kao poslovni subjekt te su joj potrebna određena financijska sredstva. U ovom slučaju rizik države poistovjećuje se s kreditnim rizikom zemlje.

Standardni (tradicionalni) pokazatelj rizika zemlje je kreditni rang dodijeljen od strane agencija za dodjelu kreditnog ranga, a napredni (suvremeni) pokazatelji rizika zemlje mogu biti utemeljeni na analizi kreditnog rizika države pomoću premije rizika na javni dug ili na analizi kreditnog rizika države pomoću cijene ugovora o zamjeni kreditnog rizika.

Rizik zemlje preljeva se direktno na sve sudionike gospodarskog sustava preko mehanizma kamatne stope pri čemu smjer kretanja kamatnih stopa ovisi o kretanju rizičnosti neke zemlje. Kako je kamatna stopa trošak za korisnike posuđenih sredstava, svako povećanje kamatnih stopa potaknuto pogoršanjem kreditnog ranga zemlje poskupljuje jednako i postojeća zaduženja i nova zaduženja.

U svrhu analize utjecaja države na trošak financiranja hrvatskih poduzeća, provedene su korelacijska i regresijska analiza pri čemu su kao mjere troška korištene kamatne stope na devizne kredite stanovništvu i gospodarstvu. Vrijednosti jednogodišnjeg i petogodišnjeg CDS-a u visokoj su pozitivnoj korelaciji, pri čemu petogodišnji CDS ima statistički značajno višu aritmetičku sredinu u promatranom periodu. Kamatne stope na devizne kredite stanovništvu i gospodarstvu u visokoj su pozitivnoj korelaciji pri čemu kamatne stope na devizne kredite stanovništvu imaju statistički značajno veće vrijednosti od onih gospodarstvu.

Na temelju provedene korelacijske analize može se zaključiti da su CDS vrijednosti, odnosno rizik zemlje, u relativno slaboj do umjerenoj pozitivnoj povezanosti sa spomenutim kamatnim stopama.

Prva regresijska analiza, s kamatnom stopom na devizne kredite stanovništvu kao zavisnom varijablom, a jednogodišnjim CDS-om te tromjesečnim Euriborom kao nezavisnim

varijablama statistički je značajna. Detaljnijim pregledom odnosa, utvrđeno je da varijabla Euribora pokazuje kao dobar prediktor promjene kamatnih stopa te je značajan na razini od 1%, dok je rizik zemlje značajan tek uz 10% rizika. Druga regresijska analiza, s kamatnom stopom na devizne kredite gospodarstvu kao zavisnom varijablom, također je statistički značajna. Međutim, tek se tromjesečni Euribor pojavljuje kao dobar prediktor kamatnih stopa.

Dakle, nije dokazan značajan utjecaj rizika zemlje na promjene kamatnih stopa na devizne kredite stanovništvu i gospodarstvu, iako među tim varijablama postoji umjerena povezanost.

Na procjenu kreditnog rizika zemlje utječu makroekonomski fundamenti, ali i čimbenici poput sklonosti riziku ili prelijevanja financijskih šokova među zemljama. Prema dosadašnjim procjenama, stope BDP-a bi sljedećih godina trebale rasti, što bi moglo rezultirati smanjenom procjenom rizika zemlje, a isti bi efekt moglo imati i očekivano smanjenje stope tromjesečnog Euribora. S druge strane, na rizik zemlje negativno bi se mogli odraziti loš kreditni rejting Hrvatske, izrazito visok udio inozemnog duga u stopi BDP-a te porast inflacije.

LITERATURA

1. Aljinović, Z., Marasović, B., Šego, B. (2011): Financijsko modeliranje, Ekonomski fakultet, Split.
2. Arnott, R., Greenwald, B., Stiglitz, J. E. (1994): Information and Economic Efficiency, Information Economics and Policy, 6 (1), str. 77-88.
3. Bodie, Z., Kane, A., Marcus, A. (2008): Investments, Mcgraw-Hill Irvin, New York.
4. Brennan, M., Kraus, A.: Efficient financing under asymmetric information, The Journal of Finance 42 (5), str. 1225-1243.
5. Čuvalo, A. (2010): Značaj rizika države u strukturi troška financiranja gospodarstva republike Hrvatske, Ekonomski fakultet, Split.
6. Deutsche Bank Research, https://www.dbresearch.com
7. Dittrich, F. (2007): The Credit Rating Industry: Competition and Regulation, doktorska disertacija, Department of Economics, Cologne, [Internet], raspoloživo na: http://ssrn.com/abstract=991821, [06.07.2016.].
8. Dumičić, M. (2015): Pokazatelji financijske stabilnosti – primjer Hrvatske, HNB, Zagreb.
9. Duvnjak, N., Mišura, M., Slišković, Ž. (2011): Bankovni management: Rizik zemlje - utjecaj na financijski sustav i pregled procjena, Ekonomski fakultet, Split.
10. Ekonomski institut Zagreb (2016): Priopćenje za javnost povodom objavljivanja novog broja publikacije Croatian Economic Outlook Quaterly, [Internet], raspoloživo na: www.eizg.hr/Download.ashx?FileID=ec66fef2-e76a-4524-9f25-8be632770f49 [25.09.2016.].
11. Ercegovac, R. (2008): Politika kamatnih stopa u bankama u kontekstu rizika, doktorska disertacija, Ekonomski fakultet, Split.
12. Europska središnja banka (2016): Makroekonomske projekcije stručnjaka ESB-a za europodručje, rujan 2016, [Internet], raspoloživo na: https://www.ecb.europa.eu/pub/pdf/other/ecbstaffprojections201609.hr.pdf?3b923937f422b86e6bb049ad1391e0d3, [21.09.2016.].
13. Foley, B. J.(1993): Tržišta kapitala, Mate, Zagreb.
14. Hefferman, S. (1996): Modern banking in theory and practice, JohnWiley & Sons, Chichester.
15. Hrvatska gospodarska komora, www.hgk.hr
16. Hrvatska narodna banka, https://www.hnb.hr/

17. HNB (2013): Odluka o adekvatnosti jamstvenog kapitala kreditnih institucija, HNB, Zagreb, [Internet], raspoloživo na: http://old.hnb.hr/propisi/odluke-nadzor-kontrola/odluke-zoki-ozujak-2010/h-odluka-o-adekvatnosti-jamstvenoga-kapitala-ki-od%2030-6-2012.pdf, [15.07.2016.].
18. HNB (2016): Financijska stabilnost, (17), [Internet], raspoloživo na: https://www.hnb.hr/documents/20182/521139/h-fs-17-2016.pdf/c4a6a955-54f8-439e-87fe-2f278612b0cd, [21.09.2016.].
19. Hrvatska gospodarska komora, www.hgk.hr, [20.07.2016.].
20. Hypo Alpe Adria Bank: Metodologija promjene kamatnih stopa u kreditnom i depozitnom poslovanju s potrošačima Hypo Alpe-Adria-Bank d.d, [Internet], raspoloživo na: http://www.hypo-alpe-adria.hr/sites/hypo-alpe-adria.hr/files/content/metodologija_promjene_kamatnih_stopa_09012013.pdf, [15.07.2016.].
21. Jakovčević, D. (2000): Upravljanje kreditnim rizikom u suvremenom bankarstvu, TEB Poslovno savjetovanje, Zagreb.
22. Jorion, P. (2001): Value at Risk, The New Benchmark for Managing Financial Risk, McGraw-Hill Inc, New York.
23. Katavić, M. (2015): Determinantne kreditnog rejtinga zemalja Europske unije, diplomski rad, Ekonomski fakultet, Split.
24. Koch, W. T., MacDonald, S. S. (1992): Bank management, The Dryden Press, Fort Worth.
25. Kunovac, D. (2013): Trošak zaduživanja odabranih zemalja Europske unije i Hrvatske– uloga prelijevanja vanjskih šokova. HNB, Zagreb.
26. Leko,V., Mates, N. (1993): Rječnik bankarstva i financija, Masmedia, Zagreb.
27. Miller, L. R., VanHoose, D. D. (1997): Moderni novac i bankarstvo, Mate, Zagreb.
28. Ministarstvo financija (2016): Smjernice za izradu DP RH za 2016 i projekcija za 2017 i 2018, Ministarstvo financija, Zagreb, [Internet], raspoloživo na: https://vlada.gov.hr/UserDocsImages/Sjednice/2016/5%20sjednica%20Vlade/5%20-%201_novo.pdf, [21.09.2016.].
29. Mishkin, S. F., Eakins, G. S. (2005): Financijska tržišta + institucije, Mate, Zagreb.
30. Moody's (2009): Rating Symbols & Definitions, [Internet], raspoloživo na: http://media.al.com/bn/other/Moody's%20rating%20scale.pdf, [15.07.2016.].

31. Pavković, A., Vedriš, D. (2011): Redefiniranje uloge agencija za kreditni rejting u suvremenom financijskom sustavu, Ekonomska misao i praksa, (1), str. 225-250, [Internet], raspoloživo na: http://hrcak.srce.hr/69719, [06.07.2016.].
32. Pojatina, D.: Dometi bankovnog posredništva, Ekonomska misao i praksa, God XIII, br. 1, str. 75 – 94.
33. Reuters, http://www.reuters.com, [20.07.2016.].
34. Saunders, A., Cornett, M. M. (2006): Financijska tržišta i institucije: moderno viđenje, Masmedia, Zagreb.
35. Standard&Poor's: Rating Methodology: Evaluating the Issuer, [Internet], raspoloživo na: http://www2.standardandpoors.com/spf/pdf/fixedincome/methodology.pdf, [06.07.2016.].
36. Stiglitz, J. E., Greenwald, B. C: (1990): Asymmetric information and the new theory of the firm: Financial constraints and risk behaviour, American Economic Review, 80 (2), str. 160-165.
37. Veselica, V. (2002): Kamatna i profitna stopa, Ekonomski pregled, 53 (7-8), str. 601-621, [Internet], raspoloživo na: http://hrcak.srce.hr/28364, [06.07.2016.].

POPIS ILUSTRACIJA

Popis tablica

Tablica 1: Usporedba i opis ocjena rejtinga S&P i Moody's 16
Tablica 2: Deskriptivna statistika varijabli..... 27
Tablica 3: Korelacijska matrica - povezanost jednogodišnjeg i petogodišnjeg CDS-a u razdoblju 31.10.2008.-30.06.2016. 28
Tablica 4: Korelacijska matrica - povezanost kamatnih stopa za devizne kredite stanovništvu i gospodarstvu u razdoblju 31.10.2008.-30.06.2016. 30
Tablica 7: Korelacijska matrica varijabli 30
Tablica 6: Sažetak modela regresijske analize sa kamatnom stopom na devizne kredite stanovništvu kao zavisnom varijablom. 32
Tablica 7: Tablica ANOVA ocijenjenog regresijskog modela s kamatnom stopom na devizne kredite stanovništvu kao zavisnom varijablom. 32
Tablica 8: Koeficijenti linearnog regresijskog modela s kamatnom stopom na devizne kredite stanovništvu kao zavisnom varijablom. 33
Tablica 9: Sažetak modela regresijske analize sa kamatnom stopom na devizne kredite gospodarstvu kao zavisnom varijablom 33
Tablica 10: Tablica ANOVA ocijenjenog regresijskog modela s kamatnom stopom na devizne kredite gospodarstvu kao zavisnom varijablom. 34
Tablica 11: Koeficijenti linearnog regresijskog modela s kamatnom stopom na devizne kredite gospodarstvu kao zavisnom varijablom. 34
Tablica 12: Kretanje nekih makroekonomskih parametara u 2014. i 2015. godini sa procjenama za 2016. 38
Tablica 13. Procjene kretanja Euribora 10.2017.-10.2018. 39

Popis slika

Slika 1: Očekivani prinos i potražnja kredita 22
Slika 2: Organizacijska struktura komercijalne banke 24
Slika 3: Kretanje salda tekućeg računa platne bilance, stope realnog rasta BDP-a te godišnjih stopa prirasta kredita domaćih poslovnih banaka i ukupnih kredita 38

Popis grafikona

Grafikon 1: Grafikon 1: Kretanje referentnih kamatnih stopa na tržištu novca (2007.-2016).11
Grafikon 2: Kretanje rejtinga Republike Hrvatske 18
Grafikon 3: Godišnja vjerojatnost bankrota Hrvatske na temelju petogodišnjeg CDS-a 19
Grafikon 4: Kretanje jednogodišnjeg i petogodišnjeg CDS-a Hrvatske za razdoblje 31.10.2008.-30.06.2016..... 27
Grafikon 5: Kretanje Euribor stope za razdoblje 31.10.2008.-30.06.2016. 28
Grafikon 6. Kretanje kamatne stope za devizne kredite u gospodarstvu i stanovništvu u razdoblju 31.10.2008.-30.06.2016. 29
Grafikon 7: Dijagram rasipanja reziduala 35
Grafikon 8: Dijagram rasipanja reziduala 36

SAŽETAK

Tradicionalni pokazatelj rizika zemlje je kreditno rangiranje od strane rang agencija. Suvremeni pokazatelji rizika zemlje su analiza javnog duga i *CDS*. Glavni cilj ovoga rada je utvrditi utječe li premija kreditnog rizika Republike Hrvatske na trošak financiranja hrvatskih poduzeća. Postoji tek slaba do umjerena pozitivna povezanost procjene rizika i kamatnih stopa na devizne kredite stanovništvu i gospodarstvu. Također, rizik zemlje nema značajan utjecaj na visinu kamatnih stopa.

Ključne riječi

Rizik zemlje, kamatne stope, CDS *spread*

SUMMARY

Traditional indicators of country risk is credit ranking made by ranking agency. Modern indicators of country risk are spread analysis of public debt and CDS spread. The main aim of this paper was to determine if the country risk premium for Croatia influences the cost of financing Croatian businesses. There is only low to mediate positive correlation between country risk and interest rates on foreign currency loans to population and economy. Also, country risk is not significant in prediction of interest rates.

Keywords

Country risk, interest rates, CDS *spread*

PRILOZI

Prilog 1. Kretanje stopa jednogodišnjega CDS-a (EUR), petogodišnjeg CDS-a (EUR), EURIBOR 3M, kamatnih stopa na devizne kredite stanovništvu te kamatnih stopa na devizne kredite gospodarstvu u razdoblju 31.10.2008-30.06.2016.

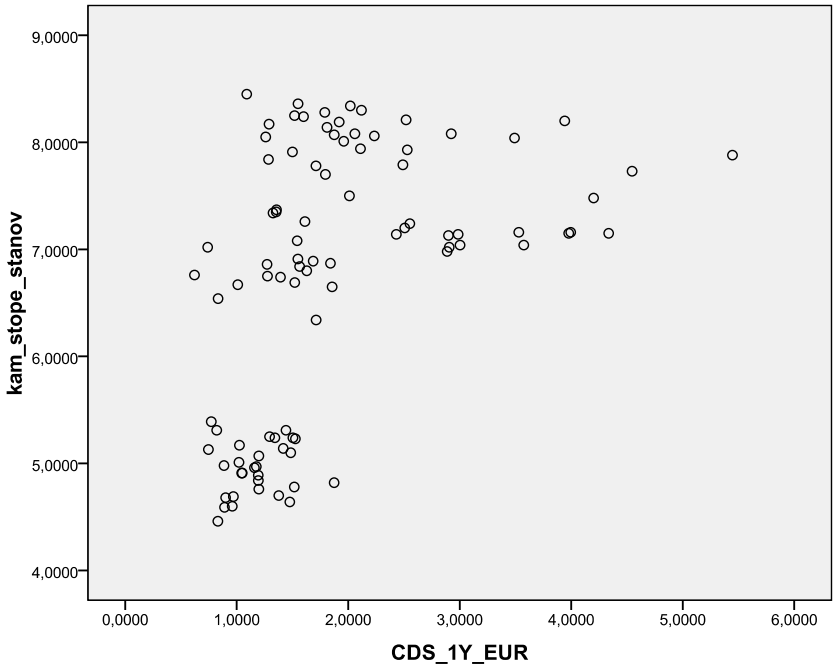
DATUM	CDS 1Y EUR	CDS 5Y EUR	EURIBOR 3M	Kamatne stope na devizne kredite stanovništvu	Kamatne stope na devizne kredite gospodarstvu
30.06.2016	0,7466	2,3770	-0,2860	5,13	5,19
31.05.2016	0,7720	2,4504	-0,2610	5,39	5,32
30.04.2016	0,8208	2,4981	-0,2510	5,31	5,27
31.03.2016	1,0244	2,6654	-0,2440	5,17	5,18
29.02.2016	1,3427	2,8621	-0,2050	5,24	5,15
31.01.2016	1,4172	2,8862	-0,1620	5,14	5,45
31.12.2015	1,5264	2,9951	-0,1310	5,23	4,94
30.11.2015	1,4420	2,9123	-0,1140	5,31	5,25
31.10.2015	1,5042	2,9724	-0,0680	5,24	5,23
30.09.2015	1,4850	2,9700	-0,0400	5,10	5,32
31.08.2015	1,2949	2,7271	-0,0330	5,25	5,39
31.07.2015	1,1986	2,6307	-0,0230	5,07	5,10
30.06.2015	1,1986	2,6314	-0,0140	4,76	5,13
31.05.2015	1,1759	2,6094	-0,0120	4,97	4,98
30.04.2015	1,1936	2,6656	-0,0050	4,89	4,95
31.03.2015	1,1589	2,6160	0,0190	4,96	4,86
28.02.2015	1,0201	2,5775	0,0390	5,01	4,87
31.01.2015	1,1938	2,7493	0,0540	4,84	4,90
31.12.2014	1,0496	2,6505	0,0780	4,91	4,83
30.11.2014	0,8859	2,4405	0,0820	4,98	4,92
31.10.2014	1,0448	2,5971	0,0860	4,91	4,83
30.09.2014	0,9604	2,5132	0,0830	4,60	4,84
31.08.2014	0,9007	2,4697	0,1630	4,68	4,71
31.07.2014	0,8908	2,4594	0,2090	4,59	4,62
30.06.2014	0,8312	2,3805	0,2070	4,46	4,53
31.05.2014	0,9702	2,5740	0,3110	4,69	4,30
30.04.2014	1,4765	3,1061	0,3390	4,64	4,21
31.03.2014	1,3771	3,0071	0,3130	4,70	4,27
28.02.2014	1,5162	3,1468	0,2860	4,78	4,31
31.01.2014	1,8736	3,4970	0,2960	4,82	4,45
31.12.2013	1,8557	3,4955	0,2870	6,65	5,58
30.11.2013	1,8406	3,4638	0,2340	6,87	5,67
31.10.2013	1,5206	3,1468	0,2300	6,69	5,84
30.09.2013	1,6287	3,2520	0,2250	6,80	5,32
31.08.2013	1,7123	3,3173	0,2240	6,34	5,02
31.07.2013	1,5647	3,1712	0,2280	6,84	5,54

30.06.2013	1,6858	3,2904	0,2180	6,89	5,91
31.05.2013	1,3932	2,9684	0,2000	6,74	5,67
30.04.2013	1,2761	2,8647	0,2070	6,75	5,84
31.03.2013	1,5489	3,1443	0,2110	6,91	6,10
28.02.2013	1,2722	2,8508	0,2090	6,86	6,24
31.01.2013	1,0098	2,5978	0,2320	6,67	6,00
31.12.2012	0,8330	2,5092	0,1870	6,54	5,82
30.11.2012	0,7395	2,3646	0,1910	7,02	6,40
31.10.2012	0,6216	2,3636	0,1970	6,76	6,05
30.09.2012	1,5424	3,3329	0,2200	7,08	6,56
31.08.2012	2,4313	4,1125	0,2780	7,14	6,49
31.07.2012	2,9063	4,3466	0,3890	7,02	6,57
30.06.2012	3,5744	4,8743	0,6530	7,04	6,23
31.05.2012	4,3359	5,4999	0,6680	7,15	6,34
30.04.2012	2,8870	4,0620	0,7080	6,98	5,85
31.03.2012	2,5067	3,5756	0,7770	7,20	6,67
29.02.2012	2,9854	4,0088	0,9830	7,14	6,49
31.01.2012	3,5297	4,4813	1,1250	7,16	6,33
31.12.2011	3,9778	4,9419	1,3560	7,15	6,66
30.11.2011	3,9956	4,9040	1,4730	7,16	6,62
31.10.2011	2,8989	3,9914	1,5910	7,13	6,49
30.09.2011	3,0030	4,1405	1,5540	7,04	6,67
31.08.2011	2,5530	3,7387	1,5420	7,24	6,84
31.07.2011	1,6118	2,8034	1,6090	7,26	6,81
30.06.2011	1,3252	2,4531	1,5470	7,34	6,75
31.05.2011	1,3539	2,3512	1,4330	7,35	6,77
30.04.2011	1,3569	2,2963	1,3850	7,37	6,58
31.03.2011	1,2852	2,1659	1,2390	7,84	7,18
28.02.2011	1,7954	2,5829	1,0940	7,70	7,34
31.01.2011	2,0111	2,6936	1,0740	7,50	6,55
31.12.2010	1,7108	2,3933	1,0060	7,78	7,03
30.11.2010	1,8746	2,5571	1,0280	8,07	7,50
31.10.2010	1,2600	2,0100	1,0450	8,05	7,41
30.09.2010	1,8100	2,5100	0,8920	8,14	7,40
31.08.2010	2,1100	2,8100	0,8860	7,94	7,55
31.07.2010	1,9600	2,6600	0,8960	8,01	7,34
30.06.2010	2,5300	3,3300	0,7670	7,93	6,71
31.05.2010	1,5000	2,3000	0,7010	7,91	7,38
30.04.2010	1,2900	2,0900	0,6630	8,17	7,16
31.03.2010	1,0900	1,8900	0,6340	8,45	7,62
28.02.2010	1,6000	2,4000	0,6560	8,24	7,59
31.01.2010	1,5500	2,4400	0,6650	8,36	7,59
31.12.2009	1,7900	2,3400	0,7000	8,28	7,55
30.11.2009	2,0188	2,4460	0,7190	8,34	8,50
31.10.2009	2,1188	2,5460	0,7200	8,30	7,80

30.09.2009	1,5188	1,9460	0,7530	8,25	7,67
31.08.2009	1,9188	2,3460	0,8210	8,19	7,89
31.07.2009	2,2344	2,4480	0,8930	8,06	7,79
30.06.2009	2,5188	2,9460	1,0990	8,21	7,88
31.05.2009	2,0594	2,2730	1,2690	8,08	7,81
30.04.2009	2,9237	2,8780	1,3650	8,08	7,43
31.03.2009	3,9415	3,9500	1,5100	8,20	7,45
28.02.2009	5,4457	5,4000	1,8250	7,88	7,06
31.01.2009	4,2007	4,1550	2,0860	7,48	6,94
31.12.2008	4,5457	4,4500	2,8920	7,73	7,26
30.11.2008	3,4915	4,1000	3,8530	8,04	7,70
31.10.2008	2,4902	2,9970	4,7600	7,79	7,62

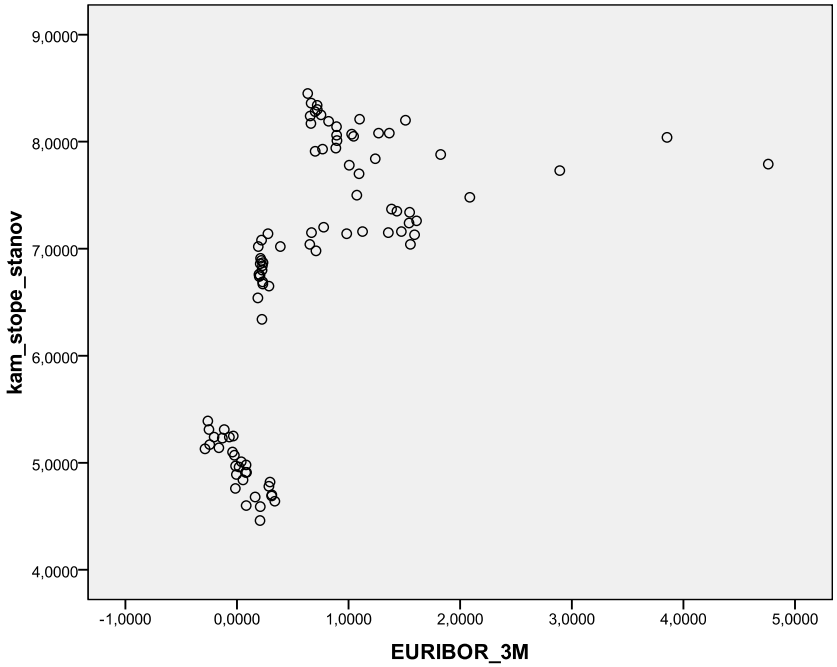
Izvor: Reuters, HNB

Prilog 2. Dijagram rasipanja za varijable jednogodišnjeg CDS-a te kamatnih stopa na devizne kredite stanovništvu.



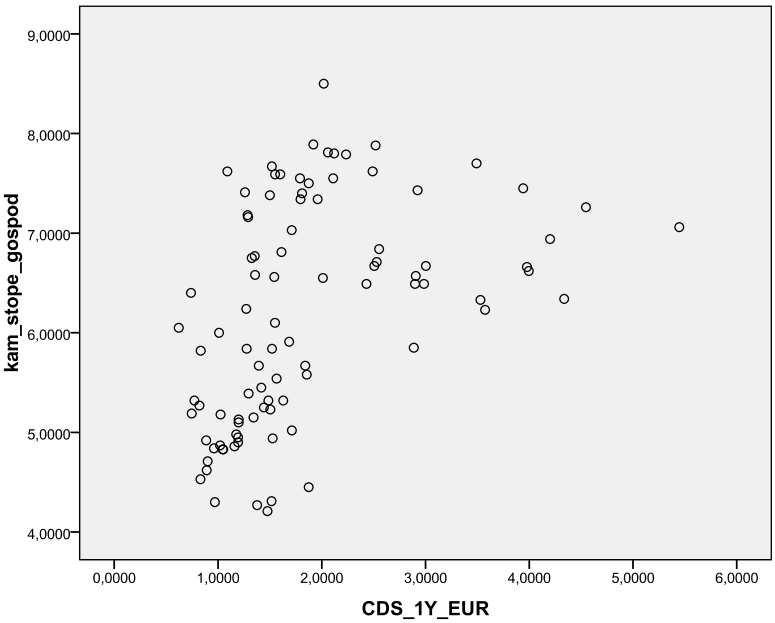
Izvor: Izrada autora na temelju podataka sa mrežnih stranica Reutersa i HNB-a

Prilog 3. Dijagram rasipanja za varijable tromjesečnog Euribora te kamatnih stopa na devizne kredite stanovništvu.



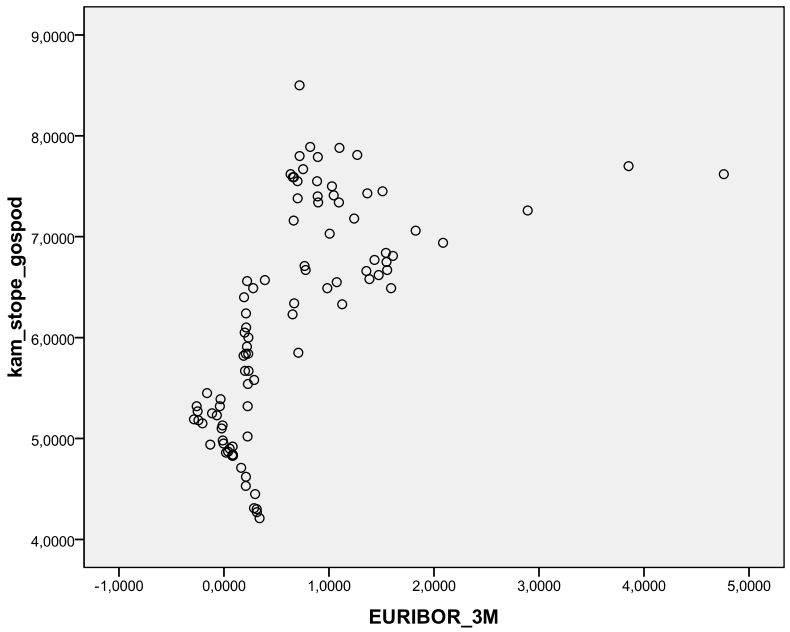
Izvor: Izrada autora na temelju podataka sa mrežnih stranica Reutersa i HNB-a

Prilog 4. Dijagram rasipanja za varijable jednogodišnjeg CDS-a te kamatnih stopa na devizne kredite gospodarstvu.



Izvor: Izrada autora na temelju podataka sa mrežnih stranica Reutersa i HNB-a

Prilog 5. Dijagram rasipanja za varijable tromjesečnog Euribora te kamatnih stopa na devizne kredite gospodarstvu.



Izvor: Izrada autora na temelju podataka sa mrežnih stranica Reutersa i HNB-a