

**SVEUČILIŠTE U SPLITU**  
**EKONOMSKI FAKULTET**

**DIPLOMSKI RAD**

**DETERMINANTE KREDITNOG REJTINGA**  
**RAZVIJENIH ZEMALJA I ZEMALJA U**  
**RAZVOJU**

**Mentor:**

**doc. dr. sc. Josip Visković**

**Student:**

**Mario Galić, univ. bacc.**

**Split, siječanj, 2018.**

## SADRŽAJ:

<b>1. UVOD .....</b>	<b>4</b>
1.1. Problem istraživanja .....	4
1.2. Predmet istraživanja .....	6
1.3. Istraživačke hipoteze .....	6
1.4. Ciljevi istraživanja.....	8
1.5. Metode istraživanja .....	8
1.6. Doprinos istraživanja .....	9
1.7. Struktura diplomskog rada .....	9
<b>2. AGENCIJE ZA KREDITNI REJTING.....</b>	<b>10</b>
2.1. Povijest i značaj kreditnih rejting agencija.....	10
2.2. Prednosti i nedostaci kreditnih rejting agencija.....	12
2.3. Tri najveće rejting agencije .....	15
2.3.1. Moody's.....	15
2.3.2. Standard & Poor .....	16
2.3.3. Fitch.....	16
2.4. Određivanje kreditnog rejtinga i simboli.....	17
<b>3. TRŽIŠTE KREDITNOG REJTINGA.....</b>	<b>19</b>
3.1. Karakteristike tržišta kreditnog rejtinga .....	19
3.2. Regulatorni okvir.....	20
3.3. Značaj kreditnih agencija za financijsku krizu 2007. ....	22
<b>4. DETERMINANTE KREDITNOG REJTINGA.....</b>	<b>24</b>
<b>5. ODNOS KLJUČNIH DETERMINANTI KREDITNOG REJTINGA I KREDITNOG REJTINGA RAZVIJENIH ZEMALJA I ZEMALJA U RAZVOJU .....</b>	<b>26</b>
5.1. Metodologija istraživanja .....	26
5.2. Podaci i varijable .....	27
5.3. Rezultati istraživanja odnosa determinanti i kreditnog rejtinga .....	29
<b>6. ZAKLJUČAK.....</b>	<b>48</b>
<b>7. LITERATURA: .....</b>	<b>50</b>

<b>POPIS GRAFIKONA TABLICA.....</b>	<b>52</b>
<b>SAŽETAK.....</b>	<b>53</b>
<b>SUMMARY.....</b>	<b>54</b>
<b>PRILOZI.....</b>	<b>55</b>

# 1. UVOD

## 1.1. Problem istraživanja

Kreditni rejting se općenito može definirati kao ocjena kreditne sposobnosti određenog subjekta da pravovremeno i kvalitetno ispunjava svoje obveze. Bach (2014) navodi da je državni kreditni rejting procjena rizika dodijeljenih obvezama središnje vlade. Pavković i Vedriš (2011) navode da je osnovni cilj agencija za kreditni rejting uklanjanje asimetričnih informacija između izdavatelja financijskog instrumenta i potencijalnog investitora. Postoje različita mišljenja o vjerodostojnosti kreditnih agencija da nepristrano i na pravedan način donose i kreiraju kreditne ocjene za pojedine subjekte.

Vodeće agencije za kreditni rejting u svijetu su: "Moody's", "Standard & Poor's" (S&P) i "Fitch". Ove tri agencije posjeduju preko 90% tržišta. Tri najveće agencije za ocjenu kreditnog rejtinga prilikom procjene kreditne sposobnosti zemalja koriste varijable koje se tiču: makroekonomskih pokazatelja i rasta, javnih financija, duga, financijskog sektora, trgovine, deviznog tečaja, političkih prilika i ostalih čimbenika.

Dakle, pri dodjeli kreditnog rejtinga pojedinoj državi promatraju se različite determinante. Kao jednu od tih determinanti, ovi autori navode dohodak po glavi stanovnika. Što je veći dohodak po glavi sposobnost vraćanja kredita bi trebala biti veća te se smatra da veći dohodak povećava kreditni rejting. Sam porast dohotka povećava poreznu bazu i raste mogućnost otplate kredita. Inflacija je također važan pokazatelj prilikom procjene kreditnog rejtinga zemlje. Mogućnost postojanja deficita koji se ogleda kroz stanje u bilanci plaćanja zemlje je važan čimbenik za ocjenu rizika, kao i povijesni podaci koji govore o problemima u otplati dugova u prošlosti.

Istraživanje Cantora i Packera (1996) ističe kako vlade često traže kreditni rejting kako bi na jednostavniji način dobile pristup međunarodnom tržištu kapitala, gdje veliki broj investitora preferira vrijednosnice s rejtingom. Svoje istraživanje pomoću metode linearne regresije provode na 49 zemalja, od kojih je većina razvijenih, a manji broj zemalja u razvoju. Uz determinante koje su važne za procjenu kreditnog rejtinga kao što su dohodak, inflacija te bilanca plaćanja, oni također ističu i povijest ne vraćanja prošlih obveza.

Istraživanje koje su proveli Monfort i Mulder (2000) pokazalo je statistički značajnima nekoliko determinanti: devizne rezerve, saldo tekućeg računa, izvoz ili uvjeti trgovine,

uravnoteženost proračuna, državni dug te politički rizik. Oni u svojem radu kao uzorak koriste 20 najvećih gospodarskih tržišta u nastajanju za razdoblje od 1994. do 1999. godine.

Bissoondoyal-Bheenick (2005) u svome radu istražuje značaj stope nezaposlenosti i jediničnog troška rada na 25 zemalja od ukupno 95 zemalja koliko ih istraživanje obuhvaća. Uzorak je obuhvaćao razvijene zemlje te zemlje u razvoju u razdoblju od 1995. do 1999. godine koje je podijelio u dvije skupine. Prvu skupinu čini 25 zemalja visokog kreditnog rejtinga, a drugu 70 zemalja slabijeg rejtinga. Na cijelom uzorku ispituje utjecaj sljedećih determinanti: BDP po glavi stanovnika, inflacija, omjer fiskalnog salda i BDP-a, udio državnog duga u BDP, realni tečaj, devizne rezerve i udio neto izvoza u BDP, pri čemu su se statistički značajnim pokazali BDP per capita i inflacija. Ostale varijable nisu se pokazale statistički značajnima za cijelo razdoblje, ali se proračunski deficit pokazao statistički značajnim za zemlje u razvoju. Također, njihovo istraživanje je pokazalo značajan utjecaj stope nezaposlenosti na razvijene zemlje, dok za zemlje u razvoju ova determinanta nije statistički značajno utjecala na kreditni rejting.

Depken et al. (2007) u svom radu koriste determinante kao što su: BDP per capita, rast, inflacija, fiskalna politika, zakašnjelo izvršenje obveza, javni dug, članstvo u EU, politički rizik, korupcija i trgovinska otvorenost. Istraživanje je provedeno na uzorku od 57 zemalja za razdoblje između 1995. i 2003. godine, a obuhvaćene su razvijene zemlje i zemlje u razvoju, kao i zemlje iz svih krajeva svijeta. Korupcija se uz BDP per capita, pokazala kao statistički najznačajnija varijabla.

Avendano, Gaillard i Nieto-Parra (2009) provode istraživanje na 83 zemlje, od kojih je većina zemalja u razvoju. Posebno su istraživali utjecaj doznaka radnika na kreditni rejting, ali i ostalih determinanti kao što su BDP per capita, rast BDP-a, godišnja inflacija, godišnja bilanca proračuna kao udio BDP-a, saldo tekućeg računa, omjer ukupnog duga i izvoza, neispunjenje prijašnjih obveza, udio pričuva u BDP-u te volatilitnost kapitalnih tijekova. Vremenski period istraživanja je od 1993.-2006. godine. Statistički najznačajnijim determinantama su se pokazali BDP per capita i volatilitnost kapitalnih tijekova.

Afonso et al. (2010) u svom radu metodom linearne regresije istražuju učinke pojedinih determinanti na kreditni rejting. Razdoblje koje obuhvaća ovo istraživanje je od 1995-2005. godine, a obuhvaća značajan broj zemalja (66 zemalja za Moody`s, 65 za S&P te 58 za Fitch).

Oni zaključuju da su osnovne determinante koje imaju kratkoročni učinak: BDP per capita, rast realnog BDP-a, državni dug i državni deficit. Efikasnost vlade, vanjski dug i strane rezerve su determinante koje imaju dugoročan učinak. Nadalje, značaj fiskalnih varijabli (državnog duga i državnog deficita) je veći nego u ranijoj literaturi.

Chee, Fah i Nassir (2015) svoje istraživanje provode na 53 zemlje u razdoblju od 2000. do 2011. godine. Ovi autori provjeravaju utjecaj devet makroekonomskih te tri kvalitativne varijable na kreditni rejting. Statistički su se najznačajnijima pokazale sljedeće varijable: povijest ne vraćanja prošlih obveza, rast realnog deviznog tečaja, pokazatelj ekonomskog razvoja, udio izvoza u BDP-u, udio stranih rezervi u BDP-u te udio vanjskog duga u BDP-u.

Navedena istraživanja ukazuju na to koje su se determinante pokazale značajnima za dodjeljivanje ocjene o kreditnoj sposobnosti zemlje. U ovom radu će se promatrati neke od ključnih determinanti kreditnog rejtinga razvijenih i zemalja u razvoju za razdoblje od 2000. do 2015. godine.

## **1.2. Predmet istraživanja**

Iz problema istraživanja proizlazi i predmet istraživanja, a on se odnosi na vezu između ključnih determinanti i kreditnog rejtinga zemalja. Na temelju detektiranih determinanti iz prethodnih istraživanja analizirati će se utjecaj istih, posebno za razvijene zemlje odnosno zemlje u razvoju.

## **1.3. Istraživačke hipoteze**

Na temelju postavljenog problema i predmeta istraživanja postaviti će se dvije hipoteze.

**H 1.: Ključne determinante kreditnog rejtinga razvijenih zemalja su: BDP per capita, rast realnog BDP-a, saldo tekućeg računa, inflacija, javni dug, nezaposlenost i razina korupcije u javnom sektoru.**

**H 2.: Ključne determinante kreditnog rejtinga zemalja u razvoju su: BDP per capita, rast realnog BDP-a, inflacija, javni dug, razina korupcije u javnom sektoru, volatilnost kapitalnih tijekova, proračunski deficit te „doing business“.**

Spomenute determinante identificirane su kao značajne u ranijim istraživanjima, koja su se bavila temom kreditnog rejtinga. Uz spomenute ovaj rad analizirat će i utjecaj varijable „doing business“ koja nije istražena do sada, a smatra se posebnom značajnom za zemlje u razvoju.

BDP po glavi stanovnika nam ukazuje na to koliko je zemlja razvijena te predstavlja jednu od osnovnih determinanti koje su ključne pri dodjeljivanju kreditnih rejtinga. Zbog toga, veći rast BDP-a po glavi stanovnika bi trebao pozitivno utjecati na kreditni rejting odnosno za očekivati je veću vjerojatnost za višim rejtingom. Rast realnog BDP-a označava napredak ekonomije i lakše podmirenje obveza te bi trebao pozitivno utjecati na razinu rejtinga. Odnos između salda tekućeg računa i razine rejtinga trebao bi također biti pozitivan ako se radi suficitu tekućeg računa. Tekući račun označava sve transakcije između zemlje i inozemstva koje su vezane za dohodak i proizvodnju u određenom razdoblju. Dakle, pozitivan saldo tekućeg računa bi označavao bolju konkurentnost gospodarstva a time i veći kreditni rejting. Varijabla „doing business“, govori o poslovnoj klimi i konkurentnosti gospodarstva određene zemlje. Korelacija između ove varijable i razine rejtinga bi također trebala biti pozitivna jer bolja poslovna klima i konkurentnost gospodarstva utječe pozitivno na kreditni rejting zemlje.

Negativna korelacija bi trebala postojati između stope inflacije i razine rejtinga. Inflacija uobičajeno označava određenu nesigurnost i nestabilnost. Viši javni dug bi također trebao smanjiti razinu kreditnog rejtinga zemlje te zbog toga očekujemo negativnu vezu između ove determinante i razine kreditnog rejtinga. Također, za očekivati je negativnu korelaciju između nezaposlenosti i razine kreditnog rejtinga. Nezaposlenost kao determinanta kreditnog rejtinga je manje zastupljena u ranijim istraživanjima od ostalih koje smo spomenuli. Za očekivati je da će porast stope nezaposlenosti dovesti do pada dohotka ekonomskih subjekata. U konačnici, to će rezultirati nižim BDP-om. To nam ukazuje na negativnu vezu između ove determinante i kreditnog rejtinga. Također, za očekivati je da će veća prisutnost korupcije u javnom sektoru neke zemlje, negativno utjecati na razinu kreditnog rejtinga. Što se tiče volatilnosti kapitalnih tijekova, porast volatilnosti može dovesti do potencijalnih rizika te se očekuje negativna veza između ove determinante i razine rejtinga. Korelacija između proračunskog deficita i razine rejtinga bi trebala biti negativna jer porast proračunskog deficita zahtjeva njegovo podmirenje javnim dugom.

#### **1.4. Ciljevi istraživanja**

Teorijski cilj ovog istraživanja je teorijski utvrditi odnos determinanti kreditnog rejtinga i kreditnog rejtinga zemalja u razvoju i razvijenih zemalja. Teorijsko utvrđivanje tog odnos je bitno za daljnju interpretaciju rezultata iz empirijskog dijela istraživanja te kako bi se dale smjernice za daljnja istraživanja. Osnovni cilj je utvrditi jesu li ključne determinante kreditnog rejtinga razvijenih i zemalja u razvoju one koje su se ključnima pokazale u prethodnim istraživanjima.

Empirijski cilj istraživanja je korištenjem statističkih metoda ispitati zadane istraživačke hipoteze te njihovo prihvaćanje ili odbacivanje. Također, empirijski cilj ovog rada je davanje smjernica za daljnja istraživanja i doprinos postojećem znanju o determinantama kreditnog rejtinga. Na taj način se može pomoći budućim nositeljima ekonomskih politika za utvrđivanje koje se determinante smatraju ključnima za bolji rejting.

#### **1.5. Metode istraživanja**

U ovom radu koristit će se sljedeće metode istraživanja:

- a) Induktivna metoda - metoda kojom je opći zaključak nastao na temelju pojedinačnih činjenica;
- b) Deduktivna metoda – metoda kojom pojedinačni zaključak dolazi iz općih stavova;
- c) Metoda analize – razdvajanje složenih pojmova na jednostavnije;
- d) Metoda sinteze – spajanje jednostavnih zaključaka u složenije zaključke;
- e) Metoda klasifikacije – podjela općeg značenja pojma na njegove pojedinačne dijelove;
- f) Metoda deskripcije – opisivanje procesa i činjenica bez znanstvenog pristupa;
- g) Komparativna metoda – usporedba sličnosti i razlika pojmova koji su isti ili slični;
- h) Metoda kompilacije – sekundarno prikupljanje podataka.

Višestrukom regresijskom analizom te metodom najmanjih kvadrata, u empirijskom dijelu rada, prikazat će se utjecaj ključnih determinanti na kreditni rejting odabranih, kako razvijenih, tako i zemalja u razvoju, te će se pokušati induktivnom metodom identificirati generalno ključne varijable za razvijene odnosno za zemlje u razvoju. Podaci će biti prikazani kroz tablice i grafikone.



## **1.6. Doprinos istraživanja**

Postoje brojna istraživanja koja se bave temom determinanti kreditnog rejtinga i njihovog utjecaja na samu razinu kreditnog rejtinga. Ovaj rad će ispitati utjecaj detektiranih determinanti iz ranijih istraživanja u nešto bližem razdoblju nego dosadašnja istraživanja. Razdoblje od 2000. do 2015. godine uključuje i globalnu financijsku krizu koja je započela krajem 2007. godine, pa će se moći istražiti jesu li neke determinante tijekom krize postale značajnije u odnosu na druge i u odnosu na razdoblje prije krize.

Također, ovaj rad će ispitati utjecaj varijable „doing business“. Ova varijabla će se ispitati odvojeno od ostalih zbog nedovoljnog broja podataka za vremenski period koji se ispituje. Rezultati koji će se dobiti mogu pomoći nositeljima ekonomske politike u različitim zemljama te ukazati na to koje determinante imaju veći utjecaj na razinu kreditnog rejtinga u razvijenim zemljama, a koje u zemljama u razvoju. Uz to, rezultati ovog rada mogli bi doprinijeti budućim istraživanjima, koja se bave ovom temom.

## **1.7. Struktura diplomskog rada**

Ovaj rad se sastoji od šest cjelina. U uvodu se predstavlja problem i predmet istraživanja, istraživačke hipoteze, ciljevi istraživanja te doprinos istraživanja. Drugo poglavlje započinje sa objašnjenjem pojma kreditne rejting agencije te će se predstaviti tri najveće kreditne rejting agencije. Također, radi lakšeg razumijevanja sadržaja ovog rada, u ovom poglavlju će se obraditi načini i simboli koje rejting agencije koriste pri dodjeli rejtinga.

U trećem poglavlju analizirat će se tržište kreditnog rejtinga. Također, govorit će se o prednostima i nedostacima kreditnih rejting agencija te će se obraditi pitanje njihove regulacije. Ovo poglavlje prikazat će i povezanost svjetskih kriza s agencijama za kreditni rejting. Determinante kreditnog rejtinga obradit će se u četvrtom poglavlju te će se pregledom prethodnih istraživanja teorijski istražiti veza između determinanti i kreditnog rejtinga.

Peto poglavlje donosi provjeru istraživačkih hipoteza koje su ranije postavljene. U šestom poglavlju postaviti će se zaključak na temelju dobivenih rezultata. Na kraju slijedi popis literature, popis tablica i slika, te sažetak na hrvatskom i engleskom jeziku.

## **2. AGENCIJE ZA KREDITNI REJTING**

### **2.1. Povijest i značaj kreditnih rejting agencija**

McClintock Ekens i Calabria (2012) govore o povijesti kreditnih rejting agencija. Navode da je početkom 19. stoljeća došlo do pojave prve agencije koja se može smatrati prethodnikom suvremenih kreditnih rejting agencija. Godine 1841. Lewis Tappan je osnovao Mercantile, agenciju kojoj je cilj bio financijsko objavljivanje odnosno smanjenje asimetričnosti informacija. Ta asimetričnost se nastojala smanjiti prikupljanjem raznih statističkih podataka o kreditnoj i poslovnoj sposobnosti pojedinog poduzeća, kako bi se smanjila mogućnost nastanka financijske krize.

Izdavači financijskih tiskovina, John Moody i Henry Poor, na prijelazu iz 20. stoljeća pretplatnicima prodaju informacije o stanju na tržištu obveznica. Ove informacije su pomagale u procjeni rizika koji je povezan s dugom poduzeća te su uključivale: kvalitetu poslovnih portfolija, sposobnost menadžmenta u ispunjavanju dužničkih obaveza i nastojanje da se smanji dugovanje.

Moody's Analyses Publishing Company 1909. godine prvi izdaje procjenu kreditne sposobnosti koja nalikuje onoj današnjoj. U razdoblju između 2. svjetskog rata i 1970-ih, financijsko tržište je bilo relativno stabilno te kreditne rejting agencije nisu bile značajno profitabilne. Rast inflacije nakon ovog razdoblja povećava potražnju za uslugama ovih agencija.

Pavković i Vedriš (2011) u svom radu kreditnu rejting agenciju nazivaju neovisnim procjeniteljem financijskih obveza (obveznice, preferencijalne dionice i komercijalni vrijednosni papiri), čiji se savjeti prihvaćaju u svrhu izvršavanja transakcija na financijskom tržištu. Razvojem kroz povijest, ove agencije su svoje poslovanje proširile na procjenu rizika svih instrumenata na financijskom tržištu. Sami razvoj financijskog tržišta te instrumenata koji su na njemu zastupljeni, povećava značaj rejting agencija. Otprilike 150 agencija za kreditni rejting poslovalo je 1999. godine. Ipak, ovaj broj se smanjio zbog udruživanja agencija te su u 2009. godini poslovale 73 agencije za kreditni rejting. Također, velike su razlike između agencija po broju zaposlenika, broju dodijeljenih rejtinga ili ukupnim

prihodima. Brzi napredak informacijskih tehnologija smanjuje potrebu za velikim brojem zaposlenika, a time se smanjuju izdavanja te povećava dobit kreditnih rejting agencija.

Značaj kreditnih rejting agencija nalazi se u smanjenju asimetrije informacija na financijskom tržištu, odnosno između investitora i izdavatelja vrijednosnog papira. Ovi autori tvrde da bi procjena kreditne sposobnosti izdavatelja bila neprihvatljiva za investitore s troškovne strane. Upravo zbog toga se javlja potreba za institucijama koje će nuditi takvu vrstu usluge. Rejting ocjene pomažu investitorima u određivanju koliki rizik su spremni prihvatiti, ali imaju i važnu ulogu u regulaciji na financijskom tržištu.

Bajo i Penava (2012) navode sudjelovanje kreditnih rejting agencija u brojnim domaćim i međunarodnim transakcijama. Neke od kreditnih rejting agencija pružaju i dodatne poslovne usluge kao što su: analiza utjecaja promjene poslovne aktivnosti na kreditni rejting dužnika, upravljanje rizicima, savjetovanje poduzeća i financijskih institucija, itd. Porast broja zemalja i financijskih institucija koje se zadužuju na tržištu dužničkih instrumenata doveo je do potražnje za kreditnim rejtingom.

Frost (2006 u Bajo i Penava, 2012) navodi da se značaj rejting agencija na globalnom tržištu kapitala povećao zbog: rasta broja izdavatelja vrijednosnica, razvoja složenih financijskih proizvoda poput vrijednosnica kolateraliziranih imovinom (engl. assets backed securities) i izvedenica, globalizacije financijskog tržišta i povećanja korištenja kreditnog rejtinga u financijskim regulativama i ugovorima. Rejting agencije sudionicima na financijskim tržištu olakšavaju pristup i pomažu u shvaćanju kreditnih rizika pojedinih vrijednosnica, ali i povećavaju transparentnost na kreditnom tržištu. Iako kreditne rejting agencije koriste različite metodologije prilikom dodjele rejtinga, postoji određen set determinanti koji je standardan za većinu rejting agencija. Jedna od važnijih uloga rejting agencija ističe se prilikom zaduživanja pojedinih zemalja gdje važnu ulogu ima sam kreditni rejting države. Rejting agencije uzimaju brojne determinante prilikom dodjeljivanja kreditnog rejtinga, bilo pojedinoj vrijednosnici ili nekoj zemlji.

Sjedinjenje Američke Države broje najviše kreditnih rejting agencija (9), Kina i Indija ih imaju pet, a Peru i Južna Koreja po četiri. Tri najveće i najpoznatije rejting agencije su: Moody's, Standard and Poor's i Fitch, koje se još nazivaju „Tri Američke Sestre“. Standard i

Poor's 2010. godine ostvaruju najveće prihode te bilježe dobit od 762 mil. dolara (Bajo i Penava, 2012).

## **2.2. Prednosti i nedostaci kreditnih rejting agencija**

Kreditne rejting agencije dodjeljivanjem kreditnih ocjena raznim vrijednosnicama bitno utječu na kamatne stope istih. Razlog tome je obrnuta veza između kamatne stope nekog dužničkog instrumenta i razine rizika istog. Nakon što određena kompanija zatraži procjenu kreditne sposobnosti, rejting agencija će što pažljivije procijeniti istu. Ipak, ne postoji jedinstvena formula kojom bi se utvrdila kreditna sposobnost kompanije te se rejting agencije oslanjaju na subjektivnu procjenu mogućnosti da kompanija otplaćuje svoje dugove. Unatoč raznim metodologijama prilikom procjene kreditne sposobnosti, kreditne ocjene treba uzimati s dozom opreza (Smith, 2013).

### **Prednosti kreditnih rejting agencija**

Raman (n.d.) prema Vepa (2006) u svom radu tvrdi da ocjene koje daju kreditne rejting agencije pružaju pomoć investitorima, ali i izdavateljima. Investitore informiraju o vjerojatnosti gubitka za određeno ulaganje s fisknim prihodom u usporedbi s drugim instrumentima. Izdavateljima ocjene služe kao marketinški alat koji osigurava lakši pristup široj bazi investitora. Stoga se kao osnovne prednosti rejting agencija mogu navesti:

- Rejtinzi kao kratak i jasan vodič pomažu investitoru u uočavanju rizika,
- Pošteno i nepristrano ocjenjivanje motivira javnost na ulaganje u obveznice, depozite i sl.
- Kreditne ocjene predstavljaju smjernice za ulagače.

Prednosti kreditnih rejtinga za izdavatelje proizlaze iz toga što tržište vjeruje u mišljenje i ocjene koje daju kreditne rejting agencije (Arora 2003, u Raman, n.d.). Raman (n.d.) prema Verma (2000) navodi da kreditni rejting izdavatelju olakšava da mobilizira štednju iz šireg dijela zainteresirane investicijske javnosti, po nižim troškovima za visoko rangirana poduzeća te pomaže manje poznatim poduzećima u pristupu tržištu kapitala. Sukladno navedenom prednosti se dodatno mogu podijeliti na prednosti za izdavatelja i prednosti za investitora.

A) Za izdavatelja:

1. Rejtinzi pružaju pristup međunarodnom „bazenu“ kapitala koji stvara tendenciju među ocijenjenim korporativnim jedinicama za održavanjem viših korporativnih standarda. To stvara bolju sliku poslovne klase zemlje na međunarodnom tržištu.
2. Rejtinzi smanjuju troškove zaduživanja jer bolje ocijenjene kompanije imaju nižu kamatnu stopu prilikom zaduživanja. Investitori koji preferiraju manji rizik će investirati u niskorizične vrijednosnice.
3. Širi pristup bazama investitora i investicijskim instrumentima povećava financijsku fleksibilnost kompanije.
4. Rejtinzi potiču tvrtke na samodisciplinu te poboljšavanje postojeće prakse kako bi zadržali postojeću rejting ocjenu i bili konkurentni. Pomoću rejtinga tvrtke procjenjuju vlastitu izvedbu. Također, to ih motivira u daljnjem radu i potiče na poduzimanje novih projekata.
5. Rejting ocjene omogućuju najbolju cijenu i vrijeme izdavanja.
6. Tvrtke s ocijenjenim instrumentima koriste rejting ocjenu kao marketinški alat u poslovanju s klijentima, zajmodavcima i vjerovnicima.
7. Kreditni rejting omogućava prepoznatljivost nekim novim ili nepoznatim izdavateljima kod investitora koji ulažu novac nakon razmatranja kreditnog rejtinga. Dakle, relativno novi izdavatelj s dobrim kreditnim rejtingom može biti stabilan na financijskom tržištu.

Rejting ocjene su jedan pokazatelj koje koriste investitori prilikom donošenja odluke o investiciji. Preko rejting ocjena investitori mogu donositi odluke i birati između instrumenata u koje žele uložiti (Khan i Akbar, 1993 u Raman, n.d.).

B) Za investitora:

1. Kreditni rejting daje jako dobre informacije o ocijenjenom proizvodu do kojih investitor ne bi mogao lako doći. Zbog toga investitor gledajući simbole može lakše prepoznati uključeni rizik te prednosti i nedostatke određenog instrumenta.
2. Pomoću rejtinga investitori mogu brže donositi odluke o ulaganju u određeni instrument.
3. Kreditna ocjena smanjuje ovisnost investitora o mišljenjima financijskih savjetnika, burzovnih brokera, financijskih posrednika i sl. Dakle, investitori mogu donositi neovisne investicijske odluke.

4. Visoko ocijenjeni vrijednosni papiri daju sigurnost ulagačima te ih štite od bankrota.
5. Kreditni rejting dodjeljuju visokokvalificirani analitičari koji prepoznaju sve kvantitativne i kvalitativne varijable tvrtke kojoj dodjeljuju rejting. Kreditna ocjena tako daje uvid u kredibilitet tvrtke izdavatelja, a time i štedi vrijeme investitorima.
6. Investitori pomoću rejtinga mogu usporediti mnoge instrumente različitih tvrtki te napraviti izbor u skladu s vlastitom preferencijom rizika.
7. Nakon dodijele ocjene nekom instrumentu, rejting agencije su uključene u nadzor nad tom ocjenom. Rejting agencije smanjuju ili povećavaju ocjenu naknadno nakon promatranja financijske snage tvrtke koja izdaje instrument. Ovaj stalni nadzor koristi investitorima, jer mogu mijenjati svoje investicijske odluke u skladu s tim.

Unatoč raznim prednostima koje donose kreditne rejting agencije, kreditni rejtingi imaju mnogo nedostataka, jer se sustav oslanja na stručne prosudbe, ali i subjektivne informacije. Dakle, teško je objektivno uspoređivati i ponovno proučavati prethodne kreditne procjene. Nedostaci kreditnih rejting agencija više pogađaju investitore nego izdavatelje (Raman, n.d.).

#### **Nedostaci kreditnih rejting agencija su:**

1. Kreditna ocjena daje se na temelju prošlih i sadašnjih rezultata tvrtke i jednom kada je ocjena dodijeljena nekom instrumentu, ona se rijetko revidira. Stoga, kreditna ocjena je statički proces i nije previše korisna investitoru koji se oslanjaju na ocjenu prilikom budućih investicijskih ocjena.
2. Kreditna ocjena nije u potpunosti pouzdana, jer izdavaljska tvrtka može prikriti podatke od istražnog tima za dodjelu rejtinga. U takvim slučajevima, kvaliteta procjene pati i donesena ocjena je nepouzdana.
3. Zbog ograničenog vremena i troškova, kreditne rejting agencije nisu sposobne u prikupljanju svih karakteristika izdavatelja te može doći do pristranosti u ocjenjivanju.
4. Ocjena se daje za određeni instrument tvrtke, a ne za tvrtku u cjelini. Stoga, ocjena nije jamstvo za stabilnost tvrtke. Ipak, mnogi investitori to ne znaju te visoku ocjenu uzimaju kao potvrdu o kredibilitetu cijele tvrtke i ostalih instrumenata tvrtke, a zbog toga ponekad gube novac.
5. Izdavaljske tvrtke imaju mogućnosti prihvatiti ili odbiti rejting. Ovo investitore dovodi u zabludu, jer ako nepovoljan rejting nije prihvatljiv nekoj tvrtki, oni idu do druge agencije kako bi dobili ocjenu za svoje instrumente. Ovaj slučaj se naziva „trgovanje rejtingima“. U cilju što većeg broja klijenata, rejting agencije će biti u

iskušenju davati povoljnije ocjene i natjecati se za niže naknade smanjujući troškove istraživanja i analize.

6. Neovisnost rejtinga je upitna, jer izdavatelji plaćaju procjenu rejtinga.
7. Kreditne rejting agencije nisu odgovorne za ocjene koje su dodijelili. Ako ne rade s velikom privrženosti, investitori mogu biti dovedeni u zabludu.
8. Moguća je i zabuna zbog postojanja mnogih rejting agencija koje različito ocjenjuju isti instrument.
9. U zapadnim zemljama rejting agencije dobrovoljno dodjeljuju ocjene, čak i kada izdavateljske tvrtke to ne traže. To čine u cilju zaštite interesa investitora. Međutim, ovo stajalište nije prisutno u Indiji.
10. Vrijeme utječe na odluke te se može dogoditi da neka tvrtka u određenoj industriji dobije niske ocjene zbog privremenog nepovoljnog stanja u toj industriji.
11. Ocjena vrijedi za vrijeme trajanja dužničkog instrumenta i valjanost joj završava s istekom tog vremena. Dakle, za kratko razdoblje valjanost ocjene vrijedi, dok tijekom dugog razdoblja podliježe sumnjama.
12. Postoje rejting agencije koje pružaju konzultantske usluge tvrtkama koje ocjenjuju.

### **2.3. Tri najveće rejting agencije**

Početak 20. stoljeća formirale su se tri, danas najveće rejting agencije na svijetu: Moody's, Standard and Poor's i Fitch. Tržišni udio ove tri agencije iznosi preko 95% svjetskih usluga rejtinga.

#### **2.3.1. Moody's**

Financijski holding, Moody's Corporation, osnovao je John Moody 1909. godine. Moody's se, uz ostale usluge, najviše bavi investitorskim uslugama, a sve do 1970. je objavljivao rejtinge državnih obveznica. Od 1970-ih, Moody's, kao i ostale rejting agencije počinje naplaćivati svoje usluge. Danas Moody's zapošljava oko 10 600 ljudi i prisutan je u 36 zemalja. Pod Moody's Corporation djeluju, Moody's Investors Service, koji pruža usluge procjene kreditnog rejtinga i istraživanja dužničkih instrumenata i vrijednosnih papira te Moody's Analytics, koji pruža usluge istraživanja i savjetovanja za kredite, ekonomske analize i financijsko upravljanje rizicima. Moody's se tijekom godina razvija u drugu po veličini

rejting agenciju na svijetu i ima značajnu ulogu na financijskom tržištu. Prihod ove korporacije u 2016. godini je iznosio 3,6 mlrd. \$ (Moody's, 2017).

### **2.3.2. Standard & Poor**

Povijest Standard&Poor's započinje 1860. Henry Varnum Poor objavljuje publikaciju o povijesti željeznica i kanala u SAD-u te tu prikazuje informacije o realnom i financijskom stanju željeznica. On sa svojim sinom osniva tvrtku H.V. and H.W. Poor Co. Nakon toga, 1906. godine, Luther Lee Blake osniva Standard Statistics Bureau, preko kojeg pruža financijske informacije o ne-željezničkim poduzećima te se 1941., Poor and Standard Statistics spajaju u jednu tvrtku pod nazivom Standard&Poor's Corporation. Krajem 90-ih i u 2000-im godinama otvaraju urede širom svijeta te su danas najveća od tri velike rejting agencije. Uz usluge ocjene kreditnog rejtinga, nude i brojne druge, kao npr. ulaganje u istraživanja (Smith, 2013).

U 28 zemalja širom svijeta i povijesti koja traje više od 150 godina, Standard&Poor's pruža visoko kvalitetne usluge u obliku kreditnih rejtinga, istraživanja i vodstva. S&P nastoji biti glavni pružatelj globalnih kreditnih mjerila i istraživanja, katalizator za rast, transparentnost i stvaranje vrijednosti na globalnim tržištima kapitala. Sjedište S&P-a je u New Yorku i zapošljava oko 10 000 ljudi (S&P Global Ratings, 2017).

### **2.3.3. Fitch**

John Knowles Fitch 1913. osniva Fitch Publishing Company. 1924. uvodi ocjenjivanje od AAA do D što je postalo standard u ovom poslovnom sektoru. Komisija za vrijednosne papire, 1975. priznaje Fitch Ratings kao prvu nacionalnu statističku rejting organizaciju. Od 1990-ih Fitch Ratings bilježi nekoliko poslovnih spajanja sa sličnim tvrtkama u Europi i Kanadi. Fitch Group posluje u više od 30 zemalja, svjetski je lider u sektoru financijskih informacijskih usluga te je u većinskom vlasništvu poduzeća Fimalac (Pariz) i Hearst Corporation (New York). Fitch Group čine: Fitch Ratings, koji se bavi kreditnim rejtingom i istraživanjima; Fitch Solutions, koji pruža podatke o kreditnom tržištu; Fitch Learning, koji pruža usluge obučavanja i razvija rješenja za globalne financijske usluge; i Business Monitor International, koji se bavi procjenama rizika zemlje i industrijske analize specijalizirane u tržištima u nastajanju (Fitch Ratings, 2017). Fitch je treća svjetska rejting agencija i ima oko



2000 zaposlenih. Fitch Ratings agencija izdaje 5,990 rejtinga financijskim institucijama od kojih su 3,212 banke i 2,294 društva za osiguranje te 289 rejtinga za države i niže razine vlasti (Bajo i Penava, 2012).

#### **2.4. Određivanje kreditnog rejtinga i simboli**

Pavković i Vedriš (2011) tvrde da metodologija pomoću koje se određuju različiti rejtingi (poduzeća, financijskih institucija, dužničkih instrumenata, zemalja i državnih izdanja dugova) mora biti usklađena sa sadašnjim promjenama u gospodarstvu, uvjetima poslovanja, raznim rizicima, krizama i sl. Najveći problem kod procjene rejting ocjene je taj što ne postoji jedinstvena formula po kojoj bi potpuno pouzdano određivao rejting. Dodjeljivanje rejtinga se osim objektivne procjene koja sadrži razne ekonomske i financijske pokazatelje, sastoji i od subjektivne procjene.

Tablica 1. prikazuje simbole koje tri najpoznatije kreditne rejting agencije koriste za prikazivanje rejtinga. Moody's, Standard i Poor's i Fitch izdaju kreditne rejtinge preko različitih simbola za utvrđivanje kreditnog rizika. Svaki simbol rejting agencije Moody's ima svoj odgovarajući simbol rejting agencija Standard and Poor's i Fitch rejtinga.

Kod rejtinga zemalja, najčešće se rejting agencije podudaraju kod ocjene rejtinga, iako ponekad postoje i čak dva stupnja razlike u dodijeljenom rejtingu. Od 2000. godine simbolima se dodaje još jedan pokazatelj, tzv. outlook. Outlook prikazuje mogući trend promjene kreditnog rejtinga države te može bit pozitivan, stabilan ili negativan. Također, outlook označava mogućnost promjena financijskih i drugih ekonomskih trendova u kraćem roku, obično od jednog do tri mjeseca (Bajo i Penava, 2012).

Rangovi rejtinga agencija imaju dva razreda, investicijski i špekulativni. Rejting dugog roka rejting agencija S&P i Fitch Ratings ima raspon ocjene od 'AAA' do BBB- za investicijski razred rejtinga, zatim od 'BB+' do D za špekulativni razred rejtinga. S iznimkom rejtinga 'AAA', 'CC', 'C' i 'D' kategorija, sve kategorije su kvantificirane i s predznakom plus ili minus. Rejtingi agencije Moody's su u rasponu od 'Aaa' do Baa3 za investicijski, a od 'Ba1' do 'C' za špekulativni razred rejtinga. S iznimkom kategorija 'Aaa', 'Ca i 'C', sve ostale kategorije imaju brojeve od jedan do tri (Bajo i Penava, 2012).

**Tablica 1. Simboli kreditnog rejtinga tri najpoznatije kreditne rejting agencije**

Interpretacija	Agencija	Moody's		Standard i Poor's		Fitch Ratings	
		Dugi rok	Kratki rok	Dugi rok	Kratki rok	Dugi rok	Kratki rok
<b>Investicijski razred rejtinga</b>							
Najviša kreditna kvaliteta		Aaa		AAA		AAA	
Visoka kreditna kvaliteta, rizičnije nego prethodne		Aa1 Aa2 Aa3	Prime-1 (P-1)	AA+ AA AA-	A1+	AA+ AA AA-	F1
Snažna sposobnost plaćanja, ekonomska situacija utječe na plaćanje		A1 A2 A3	Prime-2 (P-2)	A+ A A-	A1	A+ A A-	
Aдекватna sposobnost plaćanja, srednja kategorija, zadovoljavajuće		Baa1 Baa2 Baa3	Prime-3 (P-3)	BBB+ BBB BBB-	A2 A3	BBB+ BBB BBB-	F2 F3
Posljednji rejting u investicijskom razredu							
<b>Spekulativni razred rejtinga</b>							
Razvija se spekulativni kreditni rizik zbog ekonomskih promjena		Ba1 Ba2 Ba3		BB+ BB BB-	B	BB+ BB BB-	B
Prisutan visok spekulativni kreditni rizik, nije pogodno za investiranje, varira financijska situacija		B1 B2 B3	Not prime (NP)	B+ B B-		B+ B B-	
Visok rizik, sposobnost ovisi o povoljnim poslovnim odlukama, financijskim i ekonomskim uvjetima tržišta		Caa1 Caa2 Caa3		CCC+ CCC CCC-	C	CC+ CCC CCC- CC	C
Nenaplativo, najniža kategorija		Ca, C		C, D	D	C, D	D

Izvor: Elkhoury M (2008) u Bajo i Penava (2012), dostupno na: <http://web.efzg.hr/dok/FIN/abajo/45-57.pdf>

### 3. TRŽIŠTE KREDITNOG REJTINGA

#### 3.1. Karakteristike tržišta kreditnog rejtinga

Financijska kriza iz 2007. uzrok je brojnih rasprava o kvaliteti i sposobnosti kreditnih rejting agencija u procjeni rizika i predviđanju krize. Često se postavlja pitanje o tome jesu li rejting agencije korisne na financijskom tržištu.

White (2010) navodi da je tržište kreditnog rejtinga oligopol, zbog prevelikog utjecaja tri najveće rejting agencije. Postojanje oligopola na tržištu kreditnog rejtinga uzrokuje brojne probleme. Vodeće tri agencije upravljaju cijenama te zbog nedostatka konkurencije nisu prisiljene razvijati naprednije metode procjene kreditnih rejtinga. Problem stvara i to što izdavatelji vjeruju jedino rejting agencijama koje su poznate i priznate od investitora. Na taj način ostale rejting agencije teško mogu konkurirati „Velikoj trojci“ te se ne može razviti konkurentno tržište. Brojni autori u svojim istraživanjima analiziraju uzroke problema na tržištu rejtinga te nude preporuke koje bi pomogle u poboljšavanju uvjeta na financijskom tržištu:

##### a) Reputacija kreditnih rejting agencija

U.S. Securities and Exchange Commission (2003) navodi da je osnovna zadaća rejting agencija smanjiti asimetriju informacija između izdavatelja vrijednosnih papira i investitora koji imaju namjeru uložiti u te vrijednosne papire. Investitori vjeruju rejting agencijama s dobrom reputacijom jer agencije za kreditni rejting zbog prisutnosti oligopola ostvaruju manji trošak nego što bi bio trošak svakog pojedinog investitora. Klijenti koji traže procjenu rejtinga smatraju da su rejtingi dodijeljeni od strane agencija većinom objektivni te da ne postoje prisile od strane agencija za dodjelu kreditnog rejtinga. Uzrok tome je reputacijski mehanizam koji rejting agencijama omogućava poslovanje i ostvarivanje prihoda te je ključ njihova uspjeha.

Pavković i Vedriš (2011) govoreći o ovom problemu ističu potrebu za omogućavanjem slobode tržišnog natjecanja i stvaranje veće konkurencije na tržištu. To bi djelovalo na: snižavanje cijena za potrošače (investitore), objektivnije procjene te transparentnost i neovisnost poslovanja. Funkcioniranje financijskog sustava bi bilo omogućeno zbog djelovanja tržišnih mehanizama i slobode tržišnog natjecanja. Pomoću bolje regulacije i

nadzora bi se omogućila prilika i manjim rejting agencijama na tržištu. Uz to, ovi autori navode da bi trebalo dati značajniju ulogu tijelima koja su zadužena za nadzor.

#### b) Model plaćanja usluga rejting agencija

Sukob interesa je pojam koji se često spominje uz poslovanje kreditnih rejting agencija. „Rating shopping“ je pojam koji označava situaciju kada izdavatelj izabire onu rejting agenciju za koju smatra da ima najlakše kriterije prilikom dodijele kreditnog rejtinga. Tako dolazi do nekvalitetnih kreditnih ocjena koje u obzir uzimaju svi investitori na tržištu (Benmelech i Dlugosz, 2009). Kao jedno od rješenja nudi se veća uključenost investitora u plaćanje naknada rejting agencijama, npr. preko pretplata (Moosa, 2009 u Pavković i Vedriš, 2011). Pavković i Vedriš (2011) prema Goldstein (2009) navodi odvajanje savjetničke i rejting funkcije agencija kao rješenje sukoba interesa.

### **3.2. Regulatorni okvir**

Velike financijske krize iz 1997. i 2007. potakle su potrebu za boljom regulacijom i supervizijom poslovanja kreditnih rejting agencija. Danas rejting agencije dodjeljuju rejting, ne samo financijskim instrumentima, nego i brojnim strukturnim financijskim proizvodima. Najčešće se priča o problemu kupovanja rejtinga o kojem se ranije pisalo, ali i savjetodavnim uslugama koje nude rejting agencije (Benmelech i Dlugosz, 2009).

Početak ozbiljnije regulacije rejting agencija može se smatrati 1975. godina. Tada, SEC (U.S. Securities and Exchange Commission), agencija savezne vlade koja drži primarnu odgovornost za izvršenje saveznih zakona o vrijednosnim papirima, koja predlaže pravila vrijednosnim papirima, te regulira industriju obveznica, dionica i mogućnosti razmjene i druge aktivnosti i organizacije, uključujući i elektroničkih tržišta vrijednosnih papira u SAD-u), osniva NSRO (engl. Nationally recognized statistical rating organizations).

NSRO je osnovan s ciljem da osigurava odnosno jamči kvalitetu rejtinga. Tri najpoznatije rejting agencije su dobile NSRO-ov certifikat za kvalitetu rejtinga. Nadalje, problem nastaje zbog toga što u narednom razdoblju mali broj preostalih kreditnih rejting agencija dobiva ovaj certifikat. One rejting agencije koje su uspjele dobiti certifikat, spojile su se s jednom od tri

najveće rejting agencije. Mnoge rejting agencije su zamjerile SEC-u što nigdje nije objavio kriterije za dobivanje NSRO statusa te uz to nisu davali objašnjenja zašto određena rejting agencija nije dobila status. Ova situacija je najviše je pogodovala trima najvećim agencijama. Osim što im je smanjena konkurencija na tržištu, nitko ih nije nadgledao niti regulirao. To je nastankom posljednje krize dovelo do velike rasprave o koristi SEC-a (McClintock Ekins i Calabria, 2012).

Katz, Salinas i Stephanou, (2009) navode kako IOSCO (engl. International Organization of Securities Commissions) 2008. obnavlja kodeks poslovanja rejting agencija u cilju bolje kvalitete poslovanja agencija te izbjegavanja sukoba interesa rejting agencija. Osim ovog cilja, poboljšanje regulacije je potrebno i zbog potrebe boljeg funkcioniranja financijskog tržišta, koje se neće u velikoj mjeri oslanjati na rejtinge.

Sy (2009) u svom radu spominje potrebu za većom zaštitom kvalitete procesa dodjele rejtinga. Smatra da bi rejting agencijama trebalo biti zabranjeno davanje preporuka koje se tiču obilježja strukturnih instrumenata koje ocjenjuju, provjeranje metodologija koje rejting agencije koriste te veće znanje analitičara koji sudjeluju u dodjeljivanju rejtinga. Nadalje, ovaj autor tvrdi da je potrebno osigurati javno objavljivanje metodologija koje rejting agencije koriste.

S obzirom na oligopolsku strukturu tržišta kreditnog rejtinga, prevelik utjecaj tri najpoznatije agencije za rejting i utjecaj na aktivnosti kreditnih institucija i investicijskih društava, regulatori trebaju bolje promatrati i regulirati njihove djelatnosti. To bi u konačnici trebalo dovesti do povećanja financijske stabilnosti (Dittrich, 2007 u Pavković i Vedriš, 2011).

### **3.3. Značaj kreditnih agencija za financijsku krizu 2007.**

Krajem 2007. godine započela je jedna od najvećih globalnih financijskih kriza. Nastanak ove krize, između ostalog, stavlja se na teret kreditnim rejting agencijama. Mishkin (2011) dijeli krizu na dvije faze. Prva faza trajala je od kolovoza 2007. do kolovoza 2008. te je donekle bila pod kontrolom. Nastala je zbog gubitaka relativno malenog segmenta američkog financijskog sustava, u tvrtkama koje se bave odobravanjem hipotekarnih stambenih kredita dužnicima sa slabijom kreditnom sposobnošću. Ovaj poremećaj nije smanjio realni BDP SAD-a, čak naprotiv, on je nastavio rasti. Zatim slijedu druga faza u kojoj se pojavljuju prvi veliki problemi. Lehman Brothers 15. rujna proglašava bankrot, dan nakon osiguravateljska kuća AIG doživljava slom, a ulagači ubrzano kreću na novčani fond Reserve Primary. Mishkin zatim prikazuje kronologiju događaja velike krize. U srpnju 2007. Angelo Mozilo, osnivač i izvršni direktor Countrywide Financial Corporation ( bavi se hipotekarnim stambenim kreditima), najavljuje veliku depresiju te govori o padu tromjesečnog prihoda njegove tvrtke za jednu trećinu. Nadalje, cijena dionica Countrywidea pala za 11 posto, a indeks DJIA za 226 bodova, najviše u četiri mjeseca.

U kolovozu 2007. javlja se veliki poremećaj na kreditnim tržištima. Poznata francuska banka, BNP Paribas, obustavlja isplatu udjela u nekima od svojih novčanih fondova. Razlog ovome je iščezavanje likvidnosti na tržištu američkih vrijednosnica koje su emitirane na temelju hipotekarnih stambenih kredita, a oni su se odobrali dužnicima sa slabom kreditnom sposobnošću. Te vrijednosnice u naredna tri mjeseca imale su gubitke oko 500 mlrd. dolara. Nadalje, Europska središnja banka nudi pomoć poslovnim bankama u vidu odobravanja neograničenih iznosa kredita (kamatna stopa iznosi 4%) te ubrizgava u bankovni sustav 94,8 mlrd. eura. Zatim FED u financijski sustav ubrizgava 62 milijarde dolara za održavanje likvidnosti. Problem je što su kamatne stope u prethodne dvije godine rasle kako bi se kontrolirala inflacija.

Krajem kolovoza 2007. „TED spread“, koji označava razliku između kamate na “rizično” međubankovno posuđivanje i “nerizične” tromjesečne trezorske zapise Sjedinjenih Američkih Država (“premija na rizik”), 20. kolovoza skače na 240 bazičnih bodova. Prije toga, ova razlika se duže vrijeme kretala na oko 40 bazičnih bodova.

U rujnu 2007. poduzimaju se prve mjere kako bi se spriječila velika kriza. Američka središnja banka spušta ciljanu kamatnu stopu na pozajmice sa tadašnjih 5,25% na 2% u travnju 2008. Nakon toga, do kraja godine kamata je bila između 0 i 0,25%. TAF (Term Auction Facility), operacija koju FED pokreće u prosincu 2007. i izravno odobrava kredite svakoj banci u zemlji, a od njih prima širok spektar vrijednosnih papira, a ne samo državne obveznice. Fed razmjenjuje novac s ECB-om (20 mlrd. dolara) i Narodnom bankom Švicarske (4 mlrd.), te postaje globalni “pozajmljivač posljednjeg utočišta”.

U siječnju 2008. francuska banka Societe Generale pokušava prodati velike iznose vrijednosnih papira te dolazi do dodatnog pada cijena dionica. Dva mjeseca nakon toga, Bear Stearns ima problema s likvidnošću. Vrijednosnicama investicijskog fonda Bear Stearnsa, Moody's snižava rejting. Nekoliko dana nakon ovog događaja, Bear je raspolagao sa samo 2 mlrd. \$, a za daljnje poslovanje nedostajalo je najmanje 30 mlrd. Ben Bernanke, predsjednik FED-a, predlaže operaciju TSLF. Ova operacija označava preuzimanje nenaplativih vrijednosnih papira od investicijskih banaka s Wall Streeta. Investicijske banke bi u zamjenu dobile američke državne obveznice. Na taj način pokušalo se “odčepiti“ kreditne kanale.

Ryan (2012) u svom radu navodi kako tri najpoznatije rejting agencije u razdoblju prije nastanka krize ostvaruju veliku zaradu, tako što su rizičnim vrijednosnim papirima davale visoke rejting ocjene. Ove tri agencije su subprime kredite (kredite namjenjene za kreditiranje osoba s niskim dohotcima i niskim bonitetom) ocjenjivali ocjenom AAA. Najviše visokih ocjena dano je portfeljima koji su zasnovani na visoko rizičnim hipotekama. Mjesec dana prije propasti Lehman Brothersa, rejting agencije su mu dodijelile A rejting. Ovo su dakle neki od razloga zbog čega su rejting agencije krivci za turbulencije na financijskom tržištu.

#### 4. DETERMINANTE KREDITNOG REJTINGA

Istraživanja koja se bave determinantama kreditnog rejtinga zemalja trebala bi olakšati razumijevanje istog. Brojni autori istražuju koje su to statistički značajne determinante kreditnog rejtinga te kako utječu na kreditni rejting zemalja. Determinante koje su se najčešće pokazale značajnim u ranijim istraživanjima su: BDP per capita, realni BDP, bilanca plaćanja, omjer uvoza i izvoza, javni dug, stopa inflacije.

Istraživanje na koje se mnogi autori pozivaju te ga smatraju relevantnim prilikom obrade ovakvih ili sličnih tema, je rad Cantora i Packera iz 1996. Oni su istraživali utjecaj determinanti (BDP per capita, rast BDP-a, inflacija, fiskalni saldo, vanjski saldo, vanjski dug, ekonomski razvoj i povijest ne ispunjenja prošlih obveza) na suvereni kreditni rejting. Njihovo istraživanje je obuhvaćalo 49 zemalja, uglavnom razvijenih. Rezultati istraživanja su pokazali statistički značajnim sljedeće determinante: BDP per capita, rast BDP-a, inflacija, vanjski dug, ekonomski razvoj i povijest ne ispunjenja prošlih obveza. Iako kreditne rejting agencije prilikom dodjele rejtinga gledaju fiskalni te vanjski saldo zemlje, kod Cantora i Packera su ove determinante statistički neznačajne.

Monfort i Mulder (2000) istražuju veliki broj determinanti na 20 najveći gospodarskih tržišta u nastajanju. Najznačajnijima su se pokazale: devizne rezerve, saldo tekućeg računa, izvoz ili uvjeti trgovine, uravnoteženost proračuna, državni dug i politički rizik. Istraživanje Bissoondoyal-Bheenicka (2005) obuhvaća brojne determinante poput: BDP po glavi stanovnika, inflacija, omjer fiskalnog salda i BDP-a, udio državnog duga u BDP, realni tečaj, devizne rezerve i udio neto izvoza u BDP, a značajnima su se pokazali BDP per capita i inflacija. Istraživao se utjecaj ovih determinanti na kreditni rejting 95 zemalja, od toga 25 zemalja s najvišim, a 70 s niskim rejtingom. Također, ovaj rad istražuje i utjecaj stope nezaposlenosti i jediničnog troška rada, ali samo za 25 razvijenih zemalja. Rezultati ovog rada uglavnom su potvrdili rezultate istraživanja Cantora i Packera (1996), ali veliki broj varijabli nije statistički značajan za cijelo razdoblje promatranja.

Kasniji radovi, poput onih Depkena et al. (2007) i Avendano, Gaillard i Nieto-Parra (2009), također potvrđuju rezultate ranijih istraživanja. Kod oba istraživanja statistički se značajnim pokazao BDP per capita. Također, ovi radovi pokazuju značajan utjecaj volatilnosti kapitalnih tijekova (Avendano, Gaillard i Nieto-Parra, 2009) te korupcije (Depken et al., 2007). Nadalje,



zanimljivo je da su se determinante poput javnog duga, rasta BDP-a, inflacije te neispunjenja prošlih obveza, pokazale statistički neznčajnim u ovim istraživanjima, iako su to varijable koje se smatraju značajnim prilikom dodjele rejtinga.

Pojedini autori, poput Afonso et al. (2010), istražuju koje determinante imaju kratkoročni, a koje dugoročni učinak na kreditni rejting zemlje. Jedno od novijih istraživanja provode Chee, Fah i Nassir (2015). Oni uz makroekonomske uključuju i neke kvalitativne varijable. Njihovo istraživanje pokazuje statistički značajan utjecaj ekonomske slobode zemlje na kreditni rejting. Zaključuju da veća ekonomska sloboda privlači strane direktne investicije, a time i ulaganje u istraživanje i razvoj. Dakle, veća ekonomska sloboda zemlje trebala bi značiti bolji kreditni rejting.

S obzirom da ovo istraživanje obuhvaća dvije skupine zemalja, neće se koristiti potpuno iste varijable za obje skupine. Za razvijene zemlje to su: BDP per capita, rast realnog BDP-a, saldo tekućeg računa, inflacija, javni dug, nezaposlenost i razina korupcije u javnom sektoru. Za zemlje u razvoju varijable su: BDP per capita, rast realnog BDP-a, inflacija, javni dug, razina korupcije u javnom sektoru, volatilnost kapitalnih tijekova, proračunski deficit te „doing business“.

**Varijabla BDP per capita** ukazuje na to koliko je zemlja razvijena te predstavlja jednu od osnovnih determinanti koje su ključne pri dodjeljivanju kreditnih rejtinga. **Rast realnog BDP-a** označava napredak ekonomije i lakše podmirenje obveza. **Saldo tekućeg računa** označava sve transakcije između zemlje i inozemstva koje su vezane za dohodak i proizvodnju u određenom razdoblju. Suficit tekućeg računa trebao bi pozitivno djelovati na kreditni rejting zemlje. **Inflacija** se može objasniti kao pad vrijednosti novca. Označava određenu nestabilnost i nesigurnost te najčešće negativno djeluje na kreditni rejting. Povećanje **javnog duga** znači veću zaduženost zemlje, a to negativno utječe na kreditnu sposobnost. Veća stopa **nezaposlenosti** u konačnici dovodi i do pada BDP-a te negativno utječe na kreditni rejting zemlje. **Razina korupcije u javnom sektoru** je varijabla koja je u posljednje vrijeme sve više prisutna u društvu. Negativno djeluje na kreditni rejting zemlje. **Volatilnost kapitalnih tijekova** može dovesti do pojave neželjenih rizika te prouzročiti određene nestabilnost. Varijabla „**doing bussines**“ označava poslovnu klimu i konkurentnost gospodarstva određene zemlje.

## 5. ODNOS KLJUČNIH DETERMINANTI KREDITNOG REJTINGA I KREDITNOG REJTINGA RAZVIJENIH ZEMALJA I ZEMALJA U RAZVOJU

U ovom poglavlju predstaviti će se metodologija pomoću koje će se provesti istraživanje. Nakon toga će se definirati varijable te uzorak istraživanja, a na kraju slijede rezultati provedenih istraživanja.

### 5.1. Metodologija istraživanja

Pomoću višestruke regresijske analize ispitat će se utjecaj determinanti kreditnog rejtinga. Upotrebom programskog paketa SPSS (Statistical Package for the Social Sciences) ispituje se njihov utjecaj na kreditni rejting razvijenih te zemalja u razvoju. Višestruki regresijski model je algebarski model kojim se analitički određuje statistička povezanost jedne numeričke varijable s dvije ili više numeričkih varijabli.

Model višestruke regresije upotrebljuje se zbog pretpostavke o linearnoj povezanosti između jedne zavisne varijable i skupa nezavisnih varijabli (Jurun, 2007). Opći oblik modela glasi:

$$\hat{y} = \beta_0 + \beta_1 \cdot X_1 + \beta_2 \cdot X_2 + \dots + \beta_k \cdot X_k + e, \quad (1)$$

$\hat{y}$  – zavisna varijabla,

$X_1, X_2, \dots, X_k$  – nezavisne varijable,

$\beta_0, \beta_1, \beta_2, \dots, \beta_k$  – parametri koji se procjenjuju,

$e$  – slučajna greška.

Ovakav model ima određene pretpostavke. Prva od njih je da ne postoji problem multikolinearnosti između regresorskih varijabli, odnosno da su regresorske varijable nekorelirane. Zatim, pretpostavlja se da nije prisutan problem autokorelacije reziduala, tj. da su reziduali (slučajne greške) međusobne nekorelirani. Sljedeća pretpostavka govori o tome da slučajna greška ( $e$ ) ima normalnu distribuciju s konstantom varijancom i očekivanjem jednakim nuli.

Na kraju, pretpostavlja se da ne postoji problem heteroskedastičnosti varijance reziduala, odnosno da je varijanca slučajne greške konstantna. Metoda najmanjih kvadrata daje najbolje linearne nepristrane procjene parametara, ako su ispunjene ove pretpostavke (Jurun, 2007).

Faktor inflacije varijance (VIF) i ekvivalentni pokazatelj tolerancije (TOL) koristit će se za uočavanje problema multikolinearnosti između regresorskih varijabli (ozbiljan problem multikolinearnosti je prisutan kada je  $VIF_j > 5$ , odnosno  $TOL_j < 0,2$ ). Numerički test (Durbin-Watson) koristit će se za uočavanje problema autokorelacije reziduala. Durbin-Watson test veličina uspoređuje se s kritičnim vrijednostima  $d_l$  i  $d_u$  koje se za zadanu razinu signifikantnosti ( $\alpha$ ), veličinu uzorka ( $n$ ), i broj regresorskih varijabli ( $k$ ) očitavaju iz tablica za Durbin-Watsonov test. Ovisno o dobivenoj empirijskoj vrijednosti ovog testa može: ne postojati autokorelacija reziduala, te postojati pozitivna ili negativna autokorelacija reziduala. 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 (Jurun, 2007 i Rozga, 2008).

## 5.2. Podaci i varijable

U ovom radu provest će se regresijska analiza na razvijenim zemljama te zemljama u razvoju. Klasifikacija zemalja temelji se na podacima Svjetske Banke te će se u razvijene zemlje uključiti zemlje s visokim dohotkom po glavi stanovnika, dok se u zemlje u razvoju ubrajaju one zemlje koje imaju srednji i niži dohodak po glavi stanovnika. Provođenjem regresijske analize, moći će se uočiti postoje li razlike u ključnim determinantama kreditnog rejtinga za ove dvije skupine zemalja. Koristit će se sekundarni podaci na godišnjoj razini, za vremenski period od 2000. do 2015. godine.

Kreditni rejting je zavisna varijabla u ovoj analizi te su uzeti podaci o dugoročnom kreditnom rejtingu agencije Moody's. S obzirom da je prema ovoj agenciji oznaka kreditnog rejtinga kvalitativnog karaktera, potrebno ju je pretvoriti u numeričku vrijednost. U tablici 2 je prikazano kako se uz pomoću linearne transformacije kreirala nova varijabla, „Kreditni rejting“. Vrijednost 1 je najniža razina rejtinga, dok je vrijednost 21 najviša razina kreditnog rejtinga zemlje.

**Tablica 2. Kreiranje varijable „Kreditni rejting“**

<b>Kreditni rejting (Moody's)</b>	<b>Varijabla „Kreditni rejting“</b>
C	1
Ca	2
Caa3	3
Caa2	4
Caa1	5
B3	6
B2	7
B1	8
Ba3	9
Ba2	10
Ba1	11
Baa3	12
Baa2	13
Baa1	14
A3	15
A2	16
A1	17
Aa3	18
Aa2	19
Aa1	20
Aaa	21

Izvor: Izvor: (Afonso i Lupi, 2002)

Nezavisne varijable koje će se koristiti su odabrane na temelju ranijih istraživanja. Najveći utjecaj na kreditni rejting očekuje se od sljedećih varijabli: BDP per capita, rast realnog BDP-a, saldo tekućeg računa, inflacija te javni dug, ali uz njih će se promatrati i nezaposlenost te razina korupcije u javnom sektoru.

Ovi rezultati očekuju se kod razvijenih zemalja, dok se najveći utjecaj na kreditni rejting zemalja u razvoju očekuje od: BDP-a per capita, rasta realnog BDP-a, inflacije, javnog duga i proračunskog deficita. Uz ove varijable, ispitat će se i utječu li značajno na kreditni rejting

volatilnost kapitalnih tijekova i razina korupcije u javnom sektoru. Uz navedene varijable, posebno će se ispitati i utjecaj varijable „doing bussines“, jer je ista nedovoljno istražena u ranijim istraživanjima te nema dostupnih podataka za cijelo razdoblje koje obuhvaća ovo istraživanje.

### 5.3. Rezultati istraživanja odnosa determinanti i kreditnog rejtinga

Višestrukom regresijskom analizom ispitat će se utjecaj determinanti kreditnog rejtinga na kreditni rejting razvijenih zemalja i zemalja u razvoju. Model višestruke regresije za razvijene, kao i za zemlje u razvoju glasi:

$$\hat{Y} = \beta_0 + \beta_1 * X_1 + \beta_2 * X_2 + \beta_3 * X_3 + \beta_4 * X_4 + \beta_5 * X_5 + \beta_6 * X_6 + \beta_7 * X_7 + e. \quad (2)$$

Kod razvijenih zemalja:

$\hat{Y}$  – kreditni rejting

$X_1$  – BDP per capita

$X_2$  – rast realnog BDP-a

$X_3$  – saldo tekućeg računa

$X_4$  – inflacija

$X_5$  – javni dug

$X_6$  – nezaposlenost

$X_7$  – razina korupcije u javnom sektoru

$\beta_0, \beta_1, \dots, \beta_6$  i  $\beta_7$  – parametri koji se procjenjuju i

$e$  – slučajna greška.

Isti vrijedi i za zemlje u razvoju, s tim da je:

$X_3$  – inflacija

$X_4$  – javni dug

$X_5$  – razina korupcije u javnom sektoru

$X_6$  – volatilnost kapitalnih tijekova te

$X_7$  – proračunski deficit.

U ovom radu je ispitan utjecaj determinanti na kreditni rejting 57 zemalja, od toga 21 razvijena te 36 zemalja u razvoju. Broj zemalja je trebao biti veći, ali su se zbog nedovoljnog broja podataka određene zemlje morale izostaviti.

Na primjeru Cipra, razvijene zemlje, prikazat će se provedena višestruka regresijska analiza, dok su konačni rezultati za ostale zemlje prezentirani u tablicama pri kraju ovog poglavlja. Najprije se bira metoda izbora optimalnog skupa regresorskih varijabli. U ovom radu se koristi backward metoda izbora regresorskih varijabli. Na početku backward metode kod selektiranja u model se uključuju sve regresorske varijable i postavljaju se kriteriji za izlazak varijabli iz modela. Prvi kriterij je minimalna vrijednost F-omjera koji neka varijabla mora zadovoljiti da bi ostala u modelu. Varijable s F-omjerima manjim od kritičnoga mogu biti isključene, ako je zadovoljen i drugi kriterij za isključenje. Sljedeći kriterij za isključenje je maksimalna signifikantnost za isključenje koja iznosi 0,10. Nadalje, isključuje se varijabla koja ima najmanji koeficijent parcijalne korelacije s regresand varijablom. U slučaju da ta varijabla pri tome udovoljava i kriterijima za isključenje tada se i ona isključuje iz modela. Postupak se dalje nastavlja sve dok ima varijabli koje udovoljavaju svim navedenim kriterijima za isključenje (Jurun, 2007 i Rozga, 2008).

Tablica 3 nam daje prikaz konačnog regresijskog modela za Cipar koji se sastoji od 3 regresorske varijable: rast realnog BDP-a, javni dug i nezaposlenost. Varijabla razina korupcije u javnom sektoru nije u modelu zbog nedostatka podataka, dok su varijable BDP per capita, inflacija te saldo tekućeg računa zadovoljile kriterij izlaska iz modela.

**Tablica 3. Backward metoda**

Variables Entered/Removed <sup>a</sup>			
Model	Variables Entered	Variables Removed	Method
1	Unemployment, total (% of total labor force) (national estimate), Central government debt, total (% of GDP), Current account balance (BoP, current US\$), Inflation, consumer prices (annual %), GDP per capita (current US\$), GDP growth (annual %) <sup>b</sup>	.	Enter
2	.	Inflation, consumer prices (annual %)	Backward (criterion: Probability of F-to-remove >= ,100).
3	.	Current account balance (BoP, current US\$)	Backward (criterion: Probability of F-to-remove >= ,100).
4	.	GDP per capita (current US\$)	Backward (criterion: Probability of F-to-remove >= ,100).
a. Dependent Variable: Kreditni rejting			
b. All requested variables entered.			

Izvor: Izračun autora

Sljedeća tablica prikazuje osnovne podatke o ocijenjenom modelu gdje je kreditni rejting zavisna varijabla. Dakle, u tablici 4 prikazani su: koeficijent determinacije (R Square), korigirani koeficijent determinacije (Adjusted R Square) i procijenjena standardna devijacija regresije (Standard Error of the Estimate).

**Tablica 4. Osnovni podaci o ocijenjenom modelu**

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
4	,984 <sup>d</sup>	,969	,961	,898	2,091
d. Predictors: (Constant), Unemployment, total (% of total labor force) (national estimate), Central government debt, total (% of GDP), GDP growth (annual %)					
e. Dependent Variable: Kreditni rejting					

Izvor: Izračun autora

Koeficijent multiple determinacije ( $R^2$ ) je 0,969, a on govori da je 96,9% zbroja kvadrata ukupnih odstupanja zavisne varijable od svoje aritmetičke sredine protumačeno ovim modelom. Visoka vrijednosti ovog koeficijenta označava dobru reprezentativnost modela. Korigirani koeficijent determinacije ( $\hat{R}^2$ ) iznosi 0,961.

S obzirom da je vrijednost Durbin-Watsonova testa približna 2, u modelu ne postoji problem autokorelacije reziduala. Nadalje, tablica 5 prikazuje podatke o protumačenim, neprotumačenim i ukupnim odstupanjima ocijenjenog modela, te vrijednost F-testa s empirijskom signifikantnosti. Također, u ovoj tablici vidimo da je granična razina signifikantnosti,  $\alpha^* \approx 0$ , a ovo nam govori da je regresijski model statistički značajan pri razini signifikantnosti manjoj od 1%.

**Tablica 5. Tablica ANOVA**

Model		Sum of Squares	df	Mean Square	F	Sig.
4	Regression	303,321	3	101,107	125,352	,000 <sup>e</sup>
	Residual	9,679	12	,807		
	Total	313,000	15			

e. Predictors: (Constant), Unemployment, total (% of total labor force) (national estimate), Central government debt, total (% of GDP), GDP growth (annual %)

Izvor: Izračun autora

Sljedeća tablica donosi prikaz vrijednosti ocijenjenih parametara, njihove standardne greške i t-omjere.

**Tablica 6. Ocijenjeni linearni regresijski model**

Model	Unstandardized Coefficients		Standardized Coefficients	t	Sig.	90.0% Confidence Interval for B		Collinearity Statistics		
	B	Std. Error	Beta			Lower Bound	Upper Bound	Tolerance	VIF	
4	(Constant)	28,801	1,392		20,695	,000	26,320	31,281		
	GDP growth (annual %)	,385	,133	,280	2,897	,013	,148	,622	,277	3,612
	Central government debt, total (% of GDP)	-,072	,012	-,391	-6,158	,000	-,093	-,051	,639	1,564
	Unemployment, total (% of total labor force) (national estimate)	-,723	,087	-,733	-8,357	,000	-,878	-,569	,335	2,987

a. Dependent Variable: Kreditni rejting

Izvor: Izračun autora



Sada se može napisati analitički izraz modela koji glasi:


$$\hat{y}_t = 28,801 + 0,385 * X_{1t} - 0,072 * X_{2t} - 0,0723 * X_{3t} \quad (3)$$

Iako ovaj rad nije usmjeren na vrstu predznaka ispred parametara, vidimo da nezaposlenost i javni dug negativno utječu na kreditni rejting, dok rast realnog BDP-a ima pozitivan predznak. Također, vidimo da su svi parametri statistički značajni, a da bi utvrdili koja varijabla ima najveći relativni utjecaj na kreditni rejting, pogledat ćemo standardizirani oblik modela koji glasi:

$$\hat{z}_t = 0,280 X_{2t} - 0,391 * X_{5t} - 0,733 * X_{6t} \quad (4)$$

Iz prethodnog zapisa može se vidjeti da najveći relativni utjecaj na kreditni rejting ima nezaposlenost. Tablica 6 otkriva i nepostojanje problema multikolinearnosti između regresorskih varijabli. Sva tri parametra regresije ( $\beta_2, \beta_5$  i  $\beta_6$ ) postotak tolerancije je veći od 20%, a faktori inflacije varijance su manji od 5. Nadalje, kako bi provjerili jesu li reziduali normalno distribuirani, koristit će se histogram standardiziranih reziduala i P-P grafikon normalno distribuiranih reziduala.


**Graf 1. Histogram standardiziranih reziduala**



Izvor: Izrada autora

Također, istu stvar možemo vidjeti na P-P grafikonu (graf 2), gdje su prikazane ucrtane vrijednosti opaženih i očekivanih vjerojatnosti u slučaju normalno distribuiranih reziduala.

**Graf 2. P-P grafikon normalno distribuiranih reziduala**



Izvor: Izrada autora

Pomoću Spearmanova koeficijenta korelacije ranga, koji se temelji na korelaciji ranga između apsolutnih vrijednosti reziduala i izabranih regresorskih varijabli, provjerava se postojanje problema heteroskedastičnosti varijance reziduala. Kod ovog testa najprije se postavljaju sljedeće hipoteze:

$$H_0 \dots \dots rs = 0$$

$$H_1 \dots \dots rs \neq 0.$$

$H_0$  - ne postoji problem heteroskedastičnosti varijance reziduala u ocijenjenom modelu, tj. vrijednost Spearmanovog koeficijenta korelacije ranga između regresorske varijable i apsolutnih reziduala jednaka je 0.

$H_1$  - postoji problem heteroskedastičnosti varijance reziduala u ocijenjenom modelu, tj. vrijednost Spearmanovog koeficijenta korelacije ranga između regresorske varijable i apsolutnih reziduala različit je od 0.

**Tablica 7. Spearmanovi koeficijenti korelacije**

			absres	GDP growth (annual %)	Central government debt, total (% of GDP)	Unemployment, total (% of total labor force) (national estimate)
Spearman's rho	absres	Correlation Coefficient	1,000	-,009	,397	,059
		Sig. (2-tailed)	.	,974	,128	,829
		N	16	16	16	16
	GDP growth (annual %)	Correlation Coefficient	-,009	1,000	,403	-,697**
		Sig. (2-tailed)	,974	.	,122	,003
		N	16	16	16	16
	Central government debt, total (% of GDP)	Correlation Coefficient	,397	,403	1,000	-,312
		Sig. (2-tailed)	,128	,122	.	,240
		N	16	16	16	16
	Unemployment, total (% of total labor force) (national estimate)	Correlation Coefficient	,059	-,697**	-,312	1,000
		Sig. (2-tailed)	,829	,003	,240	.
		N	16	16	16	16

Izvor: Izračun autora

Iz ove tablice može se vidjeti empirijska signifikantnost koeficijenata korelacije, a vrijednosti su sljedeće:

$$\alpha^*_1 = 0,974, \quad \alpha^*_2 = 0,128 \quad \text{i} \quad \alpha^*_3 = 0,829.$$

S obzirom da su vrijednosti ( $\alpha^*$ ) u sva tri slučaja veća od 5%, prihvaća se nulta hipoteza da korelacija nije statistički značajna. Ovaj podatak ukazuje na to da u modelu ne postoji problem heteroskedastičnosti varijance reziduala.

**Tablica 8. Rezultati provedene regresijske analize za razvijene zemlje**

		Belgija	Cipar	Čile	Francuska	Grčka	Hong Kong
Osnovni podaci o modelu	R	0,854	0,984	0,857	0,918	0,975	0,926
	R <sup>2</sup>	0,729	0,969	0,734	0,842	0,950	0,858
	$\hat{R}^2$	0,680	0,961	0,715	0,818	0,943	0,847
	$\alpha^*$	0,001	0,000	0,000	0,000	0,000	0,000
Vrijednosti ocijenjenih nestandardiziranih regresijskih parametara i njihove pripadajuće signifikantnosti	$\beta_0 (\alpha^*)$	31,713 (0,000)	28,801 (0,00)	16,346 (0,000)	24,135 (0,000)	22,023 (0,000)	14,458 (0,000)
	$\beta_1 (\alpha^*)$	- 9,920E- 0,09 (0,002)	-	0,000 (0,000)	-	-	0,000 (0,000)
	$\beta_2 (\alpha^*)$	-	0,385 (0,013)	-	-	0,454 (0,000)	-
	$\beta_3 (\alpha^*)$	-	-	-	-1,392E -011 (0,010)	-	-
	$\beta_4 (\alpha^*)$	-	-	-	-	-	-
	$\beta_5 (\alpha^*)$	-0,088 (0,001)	-0,072 (0,000)	-	-0,049 (0,000)	-	-
	$\beta_6 (\alpha^*)$	-	-0,723 (0,000)	-	-	-0,702 (0,000)	-
	$\beta_7 (\alpha^*)$	-	-	-	-	-	-
Vrijednosti standardiziranih regresijskih parametara	$\beta_1$	-0,651	-	0,857	-	-	0,926
	$\beta_2$	-	0,280	-	-	0,330	-
	$\beta_3$	-	-	-	-0,454	-	-
	$\beta_4$	-	-	-	-	-	-
	$\beta_5$	-0,740	-0,391	-	-1,164	-	-
	$\beta_6$	-	-0,733	-	-	-0,766	-
	$\beta_7$	-	-	-	-	-	-

Izvor: Izračun autora

Iz prethodne tablice može se vidjeti da u tri od šest zemalja BDP per capita i javni dug statistički značajno djeluju na kreditni rejting. Također, u dvije zemlje vidimo da su se statistički značajnim pokazali nezaposlenost i rast realnog BDP-a.

**Tablica 9. Rezultati provedene regresijske analize za razvijene zemlje (nastavak)**

		Irska	Island	Italija	Izrael	Japan	J. Koreja
Osnovni podaci o modelu	R	0,986	0,993	0,950	0,948	0,580	0,956
	R <sup>2</sup>	0,972	0,986	0,902	0,898	0,336	0,913
	$\hat{R}^2$	0,962	0,981	0,878	0,883	0,289	0,900
	$\alpha^*$	0,000	0,000	0,000	0,000	0,019	0,000
Vrijednosti ocijenjenih nestandardiziranih regresijskih parametara i njihove pripadajuće signifikantnosti	$\beta_0 (\alpha^*)$	28,425 (0,000)	35,328 (0,000)	47,044 (0,000)	18,172 (0,000)	12,067 (0,000)	12,054 (0,000)
	$\beta_1 (\alpha^*)$	-	0,000 (0,000)	-7,938E-005 (0,056)	-	0,000 (0,019)	0,000 (0,000)
	$\beta_2 (\alpha^*)$	-0,129 (0,006)	-	-	-0,044 (0,036)	-	-
	$\beta_3 (\alpha^*)$	-	-7,727E-010 (0,009)	-	-	-	1,950E-011 (0,04)
	$\beta_4 (\alpha^*)$	-0,458 (0,003)	-0,326 (0,003)	-1,329 (0,003)	-	-	-
	$\beta_5 (\alpha^*)$	-0,048 (0,013)	-0,139 (0,000)	-0,211 (0,000)	-	-	-
	$\beta_6 (\alpha^*)$	-0,736 (0,002)	-	-	-0,166 (0,000)	-	-
	$\beta_7 (\alpha^*)$	-	-	-	-	0,580	-
Vrijednosti standardiziranih regresijskih parametara	$\beta_1$	-	-0,370	-0,195	-	-	0,614
	$\beta_2$	-0,213	-	-	-0,208	-	-
	$\beta_3$	-	-0,271	-	-	-	0,413
	$\beta_4$	-0,285	-0,228	-0,500	-	-	-
	$\beta_5$	-0,444	-0,852	-1,230	-	-	-
	$\beta_6$	-0,747	-	-	-0,945	-	-
	$\beta_7$	-	-	-	-	-	-

Izvor: Izračun autora

U tablici 9 može se vidjeti da se uz BDP per capita i javni dug, ključnom determinantom za kreditni rejting pojavljuje inflacija. Ove determinante pokazale su se statistički značajnima u tri zemlje, dok su se nezaposlenost i rast realnog BDP-a pokazali značajnima za dvije zemlje.

**Tablica 10. Rezultati provedene regresijske analize za razvijene zemlje (nastavak)**

		Kanada	Latvija	Litva	Malta	Portugal	Slovačka
Osnovni podaci o modelu	R	0,850	0,979	0,944	0,726	0,977	0,866
	R <sup>2</sup>	0,723	0,958	0,890	0,527	0,955	0,750
	$\hat{R}^2$	0,653	0,952	0,873	0,454	0,944	0,711
	$\alpha^*$	0,001	0,000	0,000	0,008	0,000	0,000
Vrijednosti ocijenjenih nestandardiziranih regresijskih parametara i njihove pripadajuće signifikantnosti	$\beta_0 (\alpha^*)$	22,273 (0,000)	22,001 (0,000)	15,601 (0,000)	13,038 (0,000)	23,687 (0,000)	18,089 (0,000)
	$\beta_1 (\alpha^*)$	-	0,000 (0,000)	-	-0,000 (0,005)	- 1,474E-010 (0,000)	-
	$\beta_2 (\alpha^*)$	-	-	-	-	-	-
	$\beta_3 (\alpha^*)$	-	-	-1,766E-010 (0,002)	1,477E-009 (0,005)	1,474E-010 (0,000)	-
	$\beta_4 (\alpha^*)$	5,124E-012 (0,008)	-	-	-	-0,645 (0,010)	-0,260 (0,000)
	$\beta_5 (\alpha^*)$	-0,061 (0,000)	-	-	-	-	-0,034 (0,060)
	$\beta_6 (\alpha^*)$	0,225 (0,054)	-0,369 (0,000)	-0,106 (0,001)	-	-0,911 (0,000)	-
	$\beta_7 (\alpha^*)$	-	-	-	-	-	-
Vrijednosti standardiziranih regresijskih parametara	$\beta_1$	-	-0,742	-	0,779	-	-
	$\beta_2$	-	-	-	-	-	-
	$\beta_3$	-	-	-0,490	-0,771	-0,352	-
	$\beta_4$	-0,533	-	-	-	-0,227	-0,848
	$\beta_5$	-0,976	-	-	-	-	-0,287
	$\beta_6$	0,422	-0,790	-0,536	-	-0,856	-
	$\beta_7$	-	-	-	-	-	-

Izvor: Izračun autora

Iz tablice 10 valja istaknuti nezaposlenost, koja se pokazala ključnom determinantom u četiri zemlje. Uz nezaposlenost, ključnima su se pokazali i BDP per capita, saldo tekućeg računa, inflacija te javni dug.

**Tablica 11. Rezultati provedene regresijske analize za razvijene zemlje (nastavak)**

		Slovenija	Španjolska	Ujedinjeno Kraljevstvo
Osnovni podaci o modelu	R	0,905	0,971	0,867
	R <sup>2</sup>	0,820	0,944	0,752
	$\hat{R}^2$	0,792	0,923	0,714
	$\alpha^*$	0,000	0,000	0,000
Vrijednosti ocijenjenih nestandardiziranih regresijskih parametara i njihove pripadajuće signifikantnosti	$\beta_0 (\alpha^*)$	19,132 (0,000)	340553 (0,000)	21,162 (0,000)
	$\beta_1 (\alpha^*)$	0,000 (0,091)	0,000 (0,023)	-
	$\beta_2 (\alpha^*)$	-	0,245 (0,086)	-
	$\beta_3 (\alpha^*)$	-1,712E-009 (0,000)	-	8,904E-012 (0,000)
	$\beta_4 (\alpha^*)$	-	-0,948 (0,007)	0,128 (0,022)
	$\beta_5 (\alpha^*)$	-	-0,189 (0,000)	-
	$\beta_6 (\alpha^*)$	-	-	-
Vrijednosti standardiziranih regresijskih parametara	$\beta_1$	-0,215	-0,244	-
	$\beta_2$	-	0,178	-
	$\beta_3$	-0,877	-	0,810
	$\beta_4$	-	-0,374	0,359
	$\beta_5$	-	-1,123	-
	$\beta_6$	-	-	-
	$\beta_7$	-	-	-

Izvor: Izračun autora

Prethodne četiri tablice (tablice 8, 9, 10, i 11) prikazuju rezultate regresijske analize za razvijene zemlje. Najprije, vidi se da su svi procijenjeni modeli statistički značajni pri razini signifikantnosti ( $\alpha^*$ ) od 5% i 10%. Također, sve zemlje osim Malte i Japana imaju zadovoljavajuće vrijednosti koeficijenta determinacije ( $R^2$ ) i korigiranog koeficijenta determinacije ( $\hat{R}^2$ ), što ukazuje na visoku reprezentativnost modela.

S obzirom da korištena backward metoda u modelu ostavlja samo one regresorske varijable koje imaju statistički značajan utjecaj na kreditni rejting te ne uzrokuju problem multikolinearnosti, vidimo da se od zemlje do zemlje razlikuju varijable koje su značajno utjecale na kreditni rejting. Od 21 razvijene zemlje, u njih 11 BDP per capita značajno djeluje na kreditni rejting. Nadalje, saldo tekućeg računa te javni dug značajno djeluju na kreditni rejting u 9 zemalja, dok nezaposlenost i inflacija imaju značajan utjecaj u nešto manjem broju

zemalja (8 i 6). Rast realnog BDP-a pokazao se značajnim u 4 zemlje, a razina korupcije u javnom sektoru ne pokazuje se značajnom za kreditni rejting razvijenih zemalja ponajviše zbog nedovoljnog broja podataka za ovaj pokazatelj.

**Tablica 12. Rezultati provedene regresijske analize za zemlje u razvoju**

		BiH	Bolivija	Brazil	Bugarska	Egipat	Ekvador
Osnovni podaci o modelu	R	0,700	0,966	0,845	0,972	0,950	0,699
	R <sup>2</sup>	0,490	0,991	0,715	0,946	0,902	0,488
	$\hat{R}^2$	0,377	0,985	0,671	0,926	0,895	0,360
	$\alpha^*$	0,048	0,000	0,000	0,000	0,000	0,039
Vrijednosti ocijenjenih nestandardiziranih regresijskih parametara i njihove pripadajuće signifikantnosti	$\beta_0 (\alpha^*)$	5,948 (0,000)	6,050 (0,000)	6,915 (0,000)	11,043 (0,000)	17,702 (0,000)	1,982 (0,108)
	$\beta_1 (\alpha^*)$	-	0,002 (0,000)	0,002 (0,000)	0,000 (0,025)	-0,003 (0,000)	0,001 (0,024)
	$\beta_2 (\alpha^*)$	-0,105 (0,027)	-	-0,604 (0,005)	0,125 (0,044)	-	-
	$\beta_3 (\alpha^*)$	-	-0,068 (0,005)	-	-0,120 (0,019)	-	-
	$\beta_4 (\alpha^*)$	-	-	-	-0,054 (0,034)	-	-
	$\beta_5 (\alpha^*)$	-	-0,572 (0,065)	-	-	-	-
	$\beta_6 (\alpha^*)$	-	2,881E-009 (0,005)	-	-	-	-1,663E-009 (0,068)
$\beta_7 (\alpha^*)$	6,026E-010 (0,052)	-	-	-	-	-7,196E-010 (0,076)	
Vrijednosti standardiziranih regresijskih parametara	$\beta_1$	-	0,977	1,181	0,545	-0,950	-
	$\beta_2$	-0,678	-	-0,714	0,225	-	-
	$\beta_3$	-	-0,178	-	-0,246	-	-
	$\beta_4$	-0,577	-	-	-0,448	-	-
	$\beta_5$	-	-0,090	-	-	-	-
	$\beta_6$	-	0,182	-	-	-	-0,538
	$\beta_7$	-	-	-	-	-	-0,458

Izvor: Izračun autora

Iz prethodne tablice može se vidjeti da se najznačajnijom determinantom za kreditni rejting pokazao BDP per capita i rast realnog BDP-a. Inflacija, javni dug i volatilnost kapitalnih tijekova pokazali su se značajnima u dvije zemlje.



**Tablica 13. Rezultati provedene regresijske analize za zemlje u razvoju (nastavak)**

		Filipini	Honduras	Hrvatska	Indija	Indonezija	Jamajka
Osnovni podaci o modelu	R	0,743	0,639	0,981	0,942	1,000	0,937
	R <sup>2</sup>	0,552	0,408	0,963	0,888	0,999	0,877
	$\hat{R}^2$	0,430	0,317	0,956	0,854	0,998	0,804
	$\alpha^*$	0,027	0,033	0,000	0,000	0,000	0,010
Vrijednosti ocijenjenih nestandardiziranih regresijskih parametara i njihove pripadajuće signifikantnosti	$\beta_0 (\alpha^*)$	11,945 (0,000)	6,543 (0,000)	15,246 (0,000)	8,385 (0,000)	3,557 (0,014)	13,495 (0,000)
	$\beta_1 (\alpha^*)$	0,002 (0,051)	-	-	0,003 (0,000)	0,002 (0,000)	-
	$\beta_2 (\alpha^*)$	-	-	0,117 (0,000)	-0,143 (0,007)	-0,428 (0,006)	-0,497 (0,031)
	$\beta_3 (\alpha^*)$	-0,827 (0,007)	0,076 (0,063)	-	-	-0,249 (0,002)	-0,211 (0,004)
	$\beta_4 (\alpha^*)$	-	-	-	-	0,179 (0,003)	-
	$\beta_5 (\alpha^*)$	-	-	-	-	-	-
	$\beta_6 (\alpha^*)$	-	-	-	8,304E- 10 (0,009)	-1,320E- 010 (0,083)	-6,094E- 009 (0,038)
$\beta_7 (\alpha^*)$	- 3,785E- 010 (0,026)	2,865E- 010 (0,077)	-0,049 (0,000)	-	-1,716E- 011 (0,014)	-	
Vrijednosti standardiziranih regresijskih parametara	$\beta_1$	0,776	-	-	1,500	0,914	-
	$\beta_2$	-	-	0,348	-0,388	-0,135	-0,635
	$\beta_3$	-0,947	0,437	-	-	-0,270	-1,041
	$\beta_4$	-	-	-	-	0,253	-
	$\beta_5$	-	-	-	-	-	-
	$\beta_6$	-	-	-	-0,673	-0,056	-0,452
	$\beta_7$	-0,717	0,414	-0,754	-	-0,127	-

Izvor: Izračun autora

Rast realnog BDP-a, inflacija i proračunski deficit značajno djeluju na kreditni rejting u četiri zemlje iz prethodne tablice. Uz njih, vrijedi istaknuti i BDP per capita te volatilnost kapitalnih tijekova.

**Tablica 14. Rezultati provedene regresijske analize za zemlje u razvoju (nastavak)**

		Jordan	J. Afrika	Katar	Kazahstan	Kolumbija	Kostarika
Osnovni podaci o modelu	R	0,716	0,643	0,789	0,558	0,885	0,566
	R <sup>2</sup>	0,513	0,414	0,623	0,311	0,784	0,320
	$\hat{R}^2$	0,432	0,323	0,560	0,205	0,722	0,272
	$\alpha^*$	0,013	0,031	0,020	0,089	0,005	0,022
Vrijednosti ocijenjenih nestandardiziranih regresijskih parametara i njihove pripadajuće signifikantnosti	$\beta_0 (\alpha^*)$	12,783 (0,000)	14,736 (0,000)	13,378 (0,000)	11,445 (0,000)	13,640 (0,000)	10,612 (0,000)
	$\beta_1 (\alpha^*)$	-	-	7,182E-005 (0,020)	0,000 (0,057)	0,000 (0,002)	-9,258E-005 (0,022)
	$\beta_2 (\alpha^*)$	0,442 (0,010)	0,289 (0,052)	-	-	-	-
	$\beta_3 (\alpha^*)$	-	-	-	-	-	-
	$\beta_4 (\alpha^*)$	-0,060 (0,048)	-	-	-	-	-
	$\beta_5 (\alpha^*)$	-	-	-	-	-	-
	$\beta_6 (\alpha^*)$	-	-	-	1,423E-008 (0,060)	-	-
$\beta_7 (\alpha^*)$	-	5,870E-011 (0,089)	-	-	-9,428E-011 (0,004)	-	
Vrijednosti standardiziranih regresijskih parametara	$\beta_1$	-	-	0,789	0,541	-1,468	0,566
	$\beta_2$	0,626	-	-	-	-	-
	$\beta_3$	-	0,458	-	-	-	-
	$\beta_4$	-0,447	-	-	-	-	-
	$\beta_5$	-	-	-	-	-	-
	$\beta_6$	-	-	-	0,534	-	-
	$\beta_7$	-	0,394	-	-	-1,229	-

Izvor: Izračun autora

BDP per capita se pokazao ključnim za kreditni rejting u četiri zemlje iz tablice 14, a proračunski deficit u dvije.

**Tablica 15. Rezultati provedene regresijske analize za zemlje u razvoju (nastavak)**

		Kuba	Kuvajt	Libanon	Mađarska	Meksiko	Moldavija
Osnovni podaci o modelu	R	0,572	0,933	0,939	0,980	0,881	0,887
	R <sup>2</sup>	0,327	0,870	0,882	0,961	0,776	0,787
	$\hat{R}^2$	0,279	0,822	0,861	0,958	0,741	0,754
	$\alpha^*$	0,021	0,000	0,000	0,000	0,000	0,000
Vrijednosti ocijenjenih nestandardiziranih regresijskih parametara i njihove pripadajuće signifikantnosti	$\beta_0 (\alpha^*)$	5,472 (0,000)	10,607 (0,000)	3,195 (0,000)	27,905 (0,000)	13,937 (0,000)	3,044 (0,000)
	$\beta_1 (\alpha^*)$	0,000 (0,000)	0,000 (0,001)	0,001 (0,000)	-	-	0,004 (0,000)
	$\beta_2 (\alpha^*)$	-	-0,084 (0,042)	-0,056 (0,063)	-	-	-
	$\beta_3 (\alpha^*)$	-	-0,410 (0,028)	-	-	-0,076 (0,045)	-
	$\beta_4 (\alpha^*)$	-	-	-	-0,178 (0,000)	-	-
	$\beta_5 (\alpha^*)$	-	-	-	-	-	-
	$\beta_6 (\alpha^*)$	-	-	-	-	-	-
$\beta_7 (\alpha^*)$	-	-8,580E-011 (0,011)	-	-	3,802E-011 (0,000)	3,541E-009 (0,033)	
Vrijednosti standardiziranih regresijskih parametara	$\beta_1$	-0,572	2,217	0,911	-	-	1,242
	$\beta_2$	-	-0,259	-0,213	-	-	-
	$\beta_3$	-	-0,518	-	-	-0,806	-
	$\beta_4$	-	-	-	-0,980	-	-
	$\beta_5$	-	-	-	-	-	-
	$\beta_6$	-	-	-	-	-	-
	$\beta_7$	-	-1,115	-	-	-0,292	0,510

Izvor: Izračun autora

Iz prethodne tablice može se vidjeti da su najznačajnije determinante BDP per capita i proračunski deficit. U dvije zemlje su se ključnima pokazali rast realnog BDP-a te inflacija. Javni dug se pokazao ključnim za kreditni rejting samo jedne zemlje.

**Tablica 16. Rezultati provedene regresijske analize za zemlje u razvoju (nastavak)**

		Oman	Pakistan	Panama	Paragvaj	Peru	Rumunjska
Osnovni podaci o modelu	R	0,971	0,523	0,957	0,666	0,854	0,984
	R <sup>2</sup>	0,943	0,274	0,916	0,444	0,729	0,969
	$\hat{R}^2$	0,919	0,222	0,895	0,404	0,651	0,961
	$\alpha^*$	0,000	0,038	0,000	0,005	0,010	0,000
Vrijednosti ocijenjenih nestandardiziranih regresijskih parametara i njihove pripadajuće signifikantnosti	$\beta_0 (\alpha^*)$	14,593 (0,000)	4,911 (0,000)	10,149 (0,000)	4,500 (0,000)	-15,994 (0,133)	10,855 (0,000)
	$\beta_1 (\alpha^*)$	0,000 (0,044)	-	0,000 (0,006)	0,001 (0,005)	0,003 (0,011)	0,000 (0,001)
	$\beta_2 (\alpha^*)$	-	0,292 (0,038)	-	-	-	-
	$\beta_3 (\alpha^*)$	-0,107 (0,080)	-	-0,066 (0,084)	-	-	-0,116 (0,000)
	$\beta_4 (\alpha^*)$	-0,224 (0,045)	-	-	-	0,610 (0,029)	-0,030 (0,040)
	$\beta_5 (\alpha^*)$	-	-	-	-	-	-
	$\beta_6 (\alpha^*)$	-	-	-	-	-	-
$\beta_7 (\alpha^*)$	-	-	-1,701E-010 (0,080)	-	-	-	
Vrijednosti standardiziranih regresijskih parametara	$\beta_1$	0,544	-	0,641	0,666	2,981	0,423
	$\beta_2$	-	0,523	-	-	-	-
	$\beta_3$	-0,052	-	-0,181	-	-	-0,653
	$\beta_4$	-0,092	-	-	-	2,291	-0,136
	$\beta_5$	-	-	-	-	-	-
	$\beta_6$	-	-	-	-	-	-
	$\beta_7$	-	-	-0,391	-	-	-

Izvor: Izračun autora

BDP per capita značajno djeluje na kreditni rejting četiri zemlje iz ove tablice. Inflacija i javni dug pokazuju se ključnima u tri zemlje, proračunski deficit i rast realnog BDP-a u jednoj.

**Tablica 17. Rezultati provedene regresijske analize za zemlje u razvoju (nastavak)**

		Rusija	Tunis	Turska	Ukrajina	Urugvaj	Venezuela
Osnovni podaci o modelu	R	0,934	0,961	0,995	0,969	0,965	0,834
	R <sup>2</sup>	0,872	0,924	0,990	0,939	0,932	0,695
	$\hat{R}^2$	0,863	0,898	0,976	0,924	0,913	0,603
	$\alpha^*$	0,000	0,000	0,003	0,000	0,000	0,006
Vrijednosti ocijenjenih nestandardiziranih regresijskih parametara i njihove pripadajuće signifikantnosti	$\beta_0 (\alpha^*)$	14,630 (0,000)	18,458 (0,000)	-2,096 (0,142)	10,532 (0,000)	11,597 (0,000)	6,357 (0,000)
	$\beta_1 (\alpha^*)$	-	0,000 (0,031)	0,002 (0,001)	-	0,000 (0,002)	0,000 (0,002)
	$\beta_2 (\alpha^*)$	-	-	0,171 (0,012)	-	-0,181 (0,005)	-
	$\beta_3 (\alpha^*)$	-	-	-0,391 (0,008)	-	-	-0,104 (0,012)
	$\beta_4 (\alpha^*)$	-0,121 (0,000)	-0,075 (0,008)	-	-0,110 (0,000)	-0,072 (0,001)	-
	$\beta_5 (\alpha^*)$	-	-	-	-	-	-
	$\beta_6 (\alpha^*)$	-	-	-	2,318E- 009 (0,001)	-	-
$\beta_7 (\alpha^*)$	-	3,560E- 010 (0,000)	9,026E- 011 (0,002)	5,054E- 011 (0,027)	-	6,042E- 011 (0,033)	
Vrijednosti standardiziranih regresijskih parametara	$\beta_1$	-	-0,909	1,408	-	0,515	0,834
	$\beta_2$	-	-	0,653	-	-0,286	-
	$\beta_3$	-	-	-0,417	-	-	-0,618
	$\beta_4$	-0,934	-1,180	-	-0,942	-0,554	-
	$\beta_5$	-	-	-	-	-	-
	$\beta_6$	-	-	-	0,307	-	-
	$\beta_7$	-	1,039	1,323	0,182	-	0,443

Izvor: Izračun autora

Tablice 12, 13, 14, 15, 16 i 17 prikazuju rezultate regresijske analize za zemlje u razvoju. Vidimo da su svi procijenjeni modeli statistički značajni pri razini signifikantnosti ( $\alpha^*$ ) od 5% i 10%, izuzev Kazahstana koji je statistički značajan samo pri razini signifikantnosti od 10%. Što se tiče koeficijenta determinacije ( $R^2$ ) i korigiranog koeficijenta determinacije ( $\hat{R}^2$ ), 12 od ukupno 36 analiziranih zemalja nema zadovoljavajuće vrijednosti ovih pokazatelja.

Za detaljnije rezultate svake zemlje pogledati u prilogu.

Kao i u slučaju razvijenih zemalja, od zemlje do zemlje razlikuju se varijable koje su značajno utjecale na kreditni rejting. BDP per capita statistički značajno utječe na kreditni rejting 26 zemalja, zatim slijede proračunski deficit (15 zemalja), rast realnog BDP-a i inflacija (14 zemalja) te javni dug koji je značajan za kreditni rejting 12 zemalja u razvoju.

U 7 zemalja volatilitnost kapitalnih tijekova značajno utječe na kreditni rejting. Konačno, u samo jednoj se zemlji (Bolivija) korupcija u javnom sektoru pokazala statistički značajnom, što je također, kao i kod razvijenih zemalja, u velikoj mjeri uzrokovano nedostatkom podataka za ovaj pokazatelj.

Na temelju ovih rezultata, može se zaključiti da je BDP per capita ističe u odnosu na ostale determinante kreditnog rejtinga. Kod razvijenih zemalja statistički značajno utječe na kreditni rejting kod 52% modela (ispitanih zemalja), dok je taj postotak veći (72%) za zemlje u razvoju. Saldo tekućeg računa, javni dug i nezaposlenost značajni su u otprilike 40% modela razvijenih zemalja, dok ovaj postotak statistički značajnog utjecaja na kreditni rejting kod zemalja u razvoju vrijedi za rast realnog BDP-a, inflaciju, te proračunski deficit. Nadalje, kod razvijenih zemalja inflacija je statistički značajna u 28% modela, dok je rast realnog BDP-a manje zastupljen (19%). Konačno, javni dug kod zemalja u razvoju značajan je u 33%, a volatilitnost kapitalnih tijekova u 19% modela.

Ovo istraživanje je, kao i ranija, pokazalo da najveći utjecaj na kreditni rejting razvijenih zemalja ima BDP-a per capita. Varijable poput rasta realnog BDP-a i inflacije, pokazale su se značajnima za kreditni rejting u ranijim istraživanjima, dok su se u ovom istraživanju pokazale manje značajnima. Nezaposlenost se kao i u radu Bissoondoyal-Bheenick (2005), pokazala ključnom determinantom za kreditni rejting razvijenih zemalja. Nadalje, saldo tekućeg računa i javni dug i u ovom istraživanju pokazuju se ključnim determinantama kreditnog rejtinga razvijenih zemalja. Korupcija se nije pokazala ključnom determinantom kao kod istraživanja Depken et al. (2007).

U odnosu na ranija istraživanja, može se vidjeti da su BDP per capita i proračunski deficit ostvarili očekivanja te su se pokazali kao ključne determinante za kreditni rejting zemalja u razvoju. Uz ove dvije varijable, ranija istraživanja poput Chee, Fah i Nassir (2015) i Afonso et al. (2010), najčešće navode rast realnog BDP-a i inflaciju, koje su se i u ovom istraživanju pokazale značajnim determinantama. Za razliku od istraživanja Avendano, Gaillard i Nieto-Parra (2009), volatilitnost kapitalnih tijekova i javni dug nisu se pokazali posebno značajnima za kreditni rejting zemalja u razvoju.

Također, višestrukom regresijskom analizom ispitan je utjecaj varijable „doing business“ te varijabli koje su se pokazale dominantno značajnima za zemlje u razvoju (BDP per capita, rast realnog BDP-a, inflacija i proračunski deficit). U analizi su uzeti podaci samo za 2015. godinu.

**Tablica 18. Ocijenjeni linearni regresijski model**

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
3	(Constant)	10,914	1,349		8,092	,000
	Rast realnog BDP-a	,367	,140	,326	2,616	,014
	Ease of doing business index (1=easiest to 185=most difficult)	-,029	,014	-,262	-2,076	,047

Izvor: Izračun autora

Model u konačnici glasi:

$$\hat{Y}_t = 10,914 + 0,367X_{1t} - 0,029X_{2t} , \quad (6)$$

što znači da kod zemalja u razvoju, statistički značajno na kreditni rejting utječu rast realnog BDP-a te varijabla „doing business“. Ostale varijable su zadovoljile kriterij izlaska iz modela.

## 6. ZAKLJUČAK

Kreditne rejting agencije prvenstveno služe smanjivanju asimetrije informacija na financijskom tržištu. Također, ocjene koje ove institucije dodjeljuju državama ili pojedinim gospodarskim subjektima imaju važnu ulogu prilikom zaduživanja tih subjekata. Kao što je ranije navedeno, tri rejting agencije (Moody's, Standard & Poor's i Fitch) imaju glavnu ulogu na tržištu kreditnih rejtinga.

Rejting agencije bi trebale uočiti te upozoriti na potencijalne rizike koji se spremaju na financijskom tržištu, ali za vrijeme posljednje krize po mnogim autorima zakazale su u tom zadatku. Kao prednosti rejting agencija, ističe se pošteno i nepristrano ocjenjivanje koje motivira javnost na ulaganje te da kreditne ocjene predstavljaju smjernice za ulagače. No, postavlja se pitanje je li to dovoljno da financijsko tržište funkcionira besprijekorno?

S obzirom da puno stvari utječe na ocjenu kreditne sposobnosti određenog subjekta, velika je vjerojatnost nastanka pogreške te donošenja ocjene koja ne predstavlja realno stanje ocjenjivanog subjekta. Upravo to je razlog da na ocjene koje dodijele rejting agencije treba gledati s posebnim oprezom.

Empirijski dio rada analizira determinante kreditnog rejtinga za razvijene zemlje i za zemlje u razvoju. Može se vidjeti da se za obje skupine zemalja BDP per capita pokazao najznačajnijom determinantom. S druge strane, rast realnog BDP-a se pokazao jako značajnim kod zemalja u razvoju, a manje kod razvijenih zemalja. Na kreditni rejting razvijenih zemalja značajno djeluju i nezaposlenost, javni dug te saldo tekućeg računa.

Što se tiče zemalja u razvoju, uz BDP per capita i rast realnog BDP-a, vrijedi izdvojiti i inflaciju te proračunski deficit. Volatilnost kapitalnih tijekova kod zemalja u razvoju te rast realnog BDP-a kod razvijenih zemalja, pokazali su se manje značajnima za kreditni rejting. Važno je uočiti kako inflacija i rast realnog BDP-a značajno djeluju na kreditni rejting zemalja u razvoju, a kod razvijenih zemalja imaju manji utjecaj. Obrnuta situacija vrijedi za javni dug.



S obzirom na postavljene hipoteze, može se uočiti da se nisu sve determinante pokazale ključnima za kreditni rejting. Rezultate ranije provedenih istraživanja za zemlje u razvoju, u najvećoj mjeri potvrdio je BDP per capita, koji se i u ovom istraživanju pokazao ključnom determinantom kreditnog rejtinga. Uz njega, očekivanja su prije svega ispunili proračunski deficit, a zatim i rast realnog BDP-a te inflacija. Ovo istraživanje nije pokazalo javni dug, korupciju i volatilnost kapitalnih tijekova ključnim determinantama kreditnog rejtinga zemalja u razvoju.

Istraživanje determinanti kreditnog rejtinga razvijenih zemalja, naglašava važnost BDP-a per capita, salda tekućeg računa, nezaposlenosti i javnog duga. Ove determinante potvrdile su postavljene hipoteze u ovom radu i ranije provedena istraživanja. Inflacija, rast realnog BDP-a i korupcija, nisu se pokazale ključnima za kreditni rejting ove skupine zemalja.

Ovaj rad prikazuje svu kompleksnost prilikom dodjele kreditnog rejtinga pojedinoj državi. Brojne su determinante koje se moraju uzeti u obzir. To predstavlja problem nositeljima ekonomske politike pojedine zemlje. Oni moraju odrediti preko kojih determinanti mogu najučinkovitije unaprijediti postojeći rejting svoje zemlje. Na temelju istraživanja s ovom tematikom, nositelji ekonomskih politika mogu uvidjeti koje su to determinante koje značajno djeluju na kreditni rejting. Sigurno je da jednake determinante nisu ključne za kreditni rejting razvijenih i zemalja u razvoju.

Važnost ovakvih istraživanja ogleda se i u tome da se determinante, odnosno njihov utjecaj na kreditni rejting mijenja tijekom godina. Stoga je potrebno nastaviti istraživanja s ovom tematikom. Također, problem može predstavljati nedostupnost podataka za pojedine zemlje koje su obuhvaćene istraživanjem. S vremenom, taj problem bi trebao biti manji.

## 7. LITERATURA:

1. Afonso A., Gomes P., Rother P. (2010): *Short and Long-run Determinants of Sovereign Debt Credit Ratings*, dostupno na: <http://onlinelibrary.wiley.com/doi/10.1002/ijfe.416/full>
2. Avendano R., Gaillard N., Nieto-Parra S. (2009): *Are workers' remittances relevant for credit ratings agencies?*, OECD development centre, Working Paper No. 282
3. Bach, S., (2014): *Financijska kriza i kreditni rejtingi država*, Pregledni znanstveni članak, dostupno na: <http://hrcak.srce.hr/143344>
4. Bajo, A., Penava, J., (2012): *Kreditne rejting agencije i kreditni rejting države*, dostupno na: [http://www.academia.edu/26862454/Kreditne\\_rejting\\_agencije\\_i\\_kreditni\\_rejting\\_dr%C5%BEave](http://www.academia.edu/26862454/Kreditne_rejting_agencije_i_kreditni_rejting_dr%C5%BEave)
5. Benmelech, E., Dlugosz, J. (2009): *The Credit Rating Crisis*, NBER Macroeconomics Annual 2009, Volume 24, University of Chicago Press
6. Bissoondoyal-Bheenick, E. (2004): *An analysis of the determinants of sovereign ratings*, School of Economics and Finance, RMIT University
7. Bissoondoyal-Bheenick E., Brooks R., Yip A.Y.N. (2005): *Determinants of sovereign ratings: A comparison of cased-based reasoning and ordered probit approaches*, Department of Econometrics and Business Statistics, Monash University, Working Paper 9/05, dostupno na: [http://webdoc.sub.gwdg.de/ebook/serien/e/monash\\_univ/wp9-05.pdf](http://webdoc.sub.gwdg.de/ebook/serien/e/monash_univ/wp9-05.pdf)
8. Cantor R., Packer, F., (1996): *Determinants and Impact of Sovereign Credit Ratings*, FRBNY Economic Policy review, Federal Reserve Bank of New York, dostupno na: [http://faculty.nps.edu/relooney/3040\\_2.pdf](http://faculty.nps.edu/relooney/3040_2.pdf)
9. Chee, S.W., Fah, C.F., Nassir, A.Md., (2015): *Macroeconomics Determinants of Sovereign Credit Ratings*, International Business Research; Vol. 8, No. 2; 2015, dostupno na: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.689.1080&rep=rep1&type=pdf>
10. Dittrich, F.,(2007) :*The Credit Rating Industry: Competition and Regulation*, Inaugural Dissertation for doctoral degree of Economic and Social Sciences of the University of Cologne
11. Depken, C., LaFountain, C., and Butters, R., (2007): *Corruption and Creditworthiness: Evidence from Sovereign Credit Ratings*, Working Papers 0601, University of Texas at Arlington, Department of Economics

12. Fitch Ratings(2015), [Internet], dostupno na:  
<https://www.fitchratings.com/web/en/dynamic/about-us/about-us.jsp> (22.10.2015.)
13. Jurun E. (2007): Kvantitativne metode u ekonomiji
14. Katz, J., Salinas, E., Stephanou, C., (2009): *Credit Rating Agencies*, The World Bank Group, Financial and private sector development, October 2009, Note number 8
15. McClintock Ekins E., Calabria, M.A., (2012): *Regulation, Market Structure, and Role of the Credit Rating Agencies*, Cato Institute Policy Analysis No. 704
16. Mishkin, F.S., (2011): *Over the Cliff: From the Subprime to the Global Financial Crisis* , Journal of Economic Perspectives, Volume 25, Number 1, Winter 2011, Pages 49–70
17. Moody's, (2015): *Moody's Corporation*, dostupno na:  
<https://www.moody's.com/Pages/atc.aspx>
18. Monfort, B., Mulder, C., (2000): *Using credit ratings for capital requirements on lending to emerging market economies - possible impact of a new Basel accord*, IMF Working Papers 00/69 , dostupno na: <https://www.imf.org/external/pubs/ft/wp/2000/wp0069.pdf>
19. Pavković, A., Vedriš, D., (2011): *Redefiniranje uloge agencija za kreditni rejting u suvremenom finansijskom sustavu*
20. Raman, R., (n.d.), dostupno na: <https://www.scribd.com/document/355929201/10-Chapter-1#>
21. Ryan, J., (2012): *The Negative Impact of Credit Rating Agencies and proposals for better regulation*, Working Paper FG 1, 2012/Nr. 01, January 2012 SWP Berlin
22. Smith, K., (2013): *History of Credit Rating Agencies and How They Work (Money Crashers)*
23. Standard&Poor's, (2016), dostupno na <https://www.spratings.com/about/who-we-are>
24. Sy, A.N.R., (2009): *The Systemic Regulation of Credit Rating Agencies and Rated Markets*, IMF Working Paper, IMF Institute, WP/09/129
25. U.S. Securities and Exchange Commission (2003): *Report on the Role and Function of Credit Rating Agencies in the Operation of the Securities Markets*, dostupno na: <https://www.sec.gov/news/studies/credratingreport0103.pdf>
26. White, L.J.,(2010): *The Credit Rating Agencies* , Journal of Economic Perspectives, Volume 24, Number 2, Spring 2010, Pages 211–226

## **POPIS GRAFIKONA TABLICA**

<b>Tablica 1. Simboli kreditnog rejtinga tri najpoznatije kreditne rejting agencije .....</b>	<b>18</b>
<b>Tablica 2. Kreiranje varijable „Kreditni rejting“ .....</b>	<b>28</b>
<b>Tablica 3. Backward metoda.....</b>	<b>31</b>
<b>Tablica 4. Osnovni podaci o ocijenjenom modelu.....</b>	<b>31</b>
<b>Tablica 5. Tablica ANOVA .....</b>	<b>32</b>
<b>Tablica 6. Ocijenjeni linearni regresijski model .....</b>	<b>32</b>
<b>Graf 1. Histogram standardiziranih reziduala.....</b>	<b>33</b>
<b>Graf 2. P-P grafikon normalno distribuiranih reziduala .....</b>	<b>34</b>
<b>Tablica 7. Spearmanovi koeficijenti korelacije .....</b>	<b>35</b>
<b>Tablica 8. Rezultati provedene regresijske analize za razvijene zemlje .....</b>	<b>36</b>
<b>Tablica 9. Rezultati provedene regresijske analize za razvijene zemlje (nastavak) .....</b>	<b>37</b>
<b>Tablica 10. Rezultati provedene regresijske analize za razvijene zemlje (nastavak) .....</b>	<b>38</b>
<b>Tablica 11. Rezultati provedene regresijske analize za razvijene zemlje (nastavak) .....</b>	<b>39</b>
<b>Tablica 12. Rezultati provedene regresijske analize za zemlje u razvoju.....</b>	<b>40</b>
<b>Tablica 13. Rezultati provedene regresijske analize za zemlje u razvoju (nastavak).....</b>	<b>41</b>
<b>Tablica 14. Rezultati provedene regresijske analize za zemlje u razvoju (nastavak).....</b>	<b>42</b>
<b>Tablica 15. Rezultati provedene regresijske analize za zemlje u razvoju (nastavak).....</b>	<b>43</b>
<b>Tablica 16. Rezultati provedene regresijske analize za zemlje u razvoju (nastavak).....</b>	<b>44</b>
<b>Tablica 17. Rezultati provedene regresijske analize za zemlje u razvoju (nastavak).....</b>	<b>45</b>
<b>Tablica 18. Ocijenjeni linearni regresijski model .....</b>	<b>47</b>

## SAŽETAK

Kreditni rejting neke zemlje je značajan pokazatelj razvijenosti i kao takav ima značajnu ulogu za tu zemlju. Nositelji ekonomske politike nastoje ostvariti što bolji kreditni rejting, a da bi to ostvarili potrebno je utvrditi koje su determinante koje značajno djeluju na kreditni rejting. Determinante koje značajno utječu na kreditni rejting nisu iste za svaku zemlju. U ovom radu najprije se teorijski, a zatim i empirijski utvrđuje značaj pojedinih determinati za kreditni rejting razvijenih i zemalja u razvoju. Cilj teorijskog dijela rada je utvrđivanje značaja kreditnih agencija za financijsko tržište te analiziranje ranijih istraživanja u cilju boljeg interpretiranja rezultata dobivenih empirijskim istraživanjem. Glavni cilj ovog istraživanja je dokazivanje jesu li determinante, navedene u dvjema hipotezama, ključne za određenu skupinu zemalja. Determinante koje su navedene kao ključne, u empirijskom dijelu rada su se pokazale statistički značajnima za modele u kojima se pojavljuju. Kao najznačajnije determinante za kreditni rejting razvijenih zemalja se javljaju: BDP per capita, saldo tekućeg računa, javni dug te nezaposlenost. Kod zemalja u razvoju to su: BDP per capita, proračunski deficit, inflacija te rast realnog BDP-a. Dakle, nisu se kao ključne pokazale sve determinante koje su na temelju ranijih istraživanja detektirane kao takve. Zbog toga treba biti oprezan prilikom donošenja odluka, kojima se nastoji poboljšati kreditni rejting zemlje.

***Ključne riječi:*** kreditni rejting, razvijene zemlje, zemlje u razvoju, determinante kreditnog rejtinga

## SUMMARY

Credit rating of some country is a significant indicator of development and has a significant role for each country. Economic policy leaders seek to achieve a better credit rating, and in order to achieve this, it is necessary to determine which determinants are significant for credit rating. Determinants that have a significant impact on credit rating are not the same for each country. In this work, theoretically, and then empirically, is determined the importance of certain determinants for credit rating of developed and developing countries. The aim of the theoretical part is to determine the importance of credit agencies for the financial market and to analyze earlier research in order to better interpret the results obtained by empirical research. The main purpose of this research is to prove are determinants listed in two hypotheses crucial for a particular group of countries. The determinants that are crucial, in the empirical part of the work, have been statistically significant for the models they appear in. The most important determinants for the credit rating of developed countries are: GDP per capita, current account balance, public debt and unemployment. In developing countries, they are: GDP per capita, budget deficit, inflation and real GDP growth. Thus, all the determinants that were detected as crucial in earlier researches, are not crucial in this research. This is why is important to be careful at making decision, which can improve the credit rating of the country.

**Keywords:** credit rating, developed countries, developing countries, credit rating determinants

## PRILOZI

### Prilog 1. Korištene varijable i njihovi izvori

VARIJABLA	IZVOR
Kreditni rejting	Moody's
BDP per capita	World Bank
Rast realnog BDP-a	World Bank
Inflacija	World Bank
Javni dug	World Bank
Saldo tekućeg računa	World Bank
Volatilnost kapitalnih tijekova	World Bank
Razina korupcije u javnom sektoru	World Bank
Nezaposlenost	World Bank

Izvor: Izrada autora

### Prilog 2. Prikaz osnovnih podataka o modelu i tablice Anova (Belgija)

Model Summary <sup>f</sup>						
Model	R	R Square	Adjusted Square	R	Std. Error of the Estimate	Durbin-Watson
5	,854 <sup>e</sup>	,729	,680		,562	1,641
e. Predictors: (Constant), Central government debt, total (% of GDP), GDP per capita (current US\$)						
f. Dependent Variable: Kr rejting						

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
5	Regression	9,379	2	4,690	14,832	,001 <sup>f</sup>
	Residual	3,478	11	,316		
	Total	12,857	13			
f. Predictors: (Constant), Central government debt, total (% of GDP), GDP per capita (current US\$)						

Izvor: Izračun autora

### Prilog 3. Prikaz osnovnih podataka o modelu i tablice Anova (Cipar)

Model Summary <sup>e</sup>						
Model	R	R Square	Adjusted R Square	R	Std. Error of the Estimate	Durbin-Watson
4	,984 <sup>d</sup>	,969	,961		,898	2,091
d. Predictors: (Constant), Unemployment, total (% of total labor force) (national estimate), Central government debt, total (% of GDP), GDP growth (annual %)						
e. Dependent Variable: Kr rejting						

ANOVA <sup>a</sup>						
4	Regression	303,321	3	101,107	125,352	,000 <sup>e</sup>
	Residual	9,679	12	,807		
	Total	313,000	15			
e. Predictors: (Constant), Unemployment, total (% of total labor force) (national estimate), Central government debt, total (% of GDP), GDP growth (annual %)						

Izvor: Izračun autora

### Prilog 4. Prikaz osnovnih podataka o modelu i tablice Anova (Čile)

Model Summary <sup>f</sup>						
Model	R	R Square	Adjusted R Square	R	Std. Error of the Estimate	Durbin-Watson
5	,857 <sup>e</sup>	,734	,715		,267	,707
e. Predictors: (Constant), GDP per capita (current US\$)						
f. Dependent Variable: kr rejting						

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
5	Regression	2,753	1	2,753	38,654	,000 <sup>f</sup>
	Residual	,997	14	,071		
	Total	3,750	15			
f. Predictors: (Constant), GDP per capita (current US\$)						

Izvor: Izračun autor



### Prilog 5. Prikaz osnovnih podataka o modelu i tablice Anova (Francuska)

Model Summary <sup>f</sup>						
Model	R	R Square	Adjusted Square	R	Std. Error of the Estimate	Durbin-Watson
5	,918 <sup>e</sup>	,842	,818		,257	1,450
e. Predictors: (Constant), Current account balance (BoP, current US\$), Central government debt, total (% of GDP)						
f. Dependent Variable: Kr rejting						

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
5	Regression	4,578	2	2,289	34,630	,000 <sup>f</sup>
	Residual	,859	13	,066		
	Total	5,438	15			
f. Predictors: (Constant), Current account balance (BoP, current US\$), Central government debt, total (% of GDP)						

Izvor: Izračun autora

### Prilog 6. Prikaz osnovnih podataka o modelu i tablice Anova (Grčka)

Model Summary <sup>e</sup>						
Model	R	R Square	Adjusted Square	R	Std. Error of the Estimate	Durbin-Watson
4	,975 <sup>d</sup>	,950	,943		1,584	1,911
d. Predictors: (Constant), GDP growth (annual %), Unemployment, total (% of total labor force) (national estimate)						
e. Dependent Variable: Kr rejting						

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
4	Regression	623,399	2	311,700	124,295	,000 <sup>e</sup>
	Residual	32,601	13	2,508		
	Total	656,000	15			
e. Predictors: (Constant), GDP growth (annual %), Unemployment, total (% of total labor force) (national estimate)						

Izvor: Izračun autora

### Prilog 7. Prikaz osnovnih podataka o modelu i tablice Anova (Hong Kong)

Model Summary <sup>f</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
5	,926 <sup>e</sup>	,858	,847	,363	,852
e. Predictors: (Constant), GDP per capita (current US\$)					
f. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
5	Regression	11,095	1	11,095	84,301	,000 <sup>f</sup>
	Residual	1,843	14	,132		
	Total	12,938	15			
f. Predictors: (Constant), GDP per capita (current US\$)						

Izvor: Izračun autora

### Prilog 8. Prikaz osnovnih podataka o modelu i tablice Anova (Irska)

Model Summary <sup>c</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
2	,986 <sup>b</sup>	,972	,962	,845	1,593
b. Predictors: (Constant), GDP growth (annual %), Central government debt, total (% of GDP), Inflation, consumer prices (annual %), Unemployment, total (% of total labor force) (national estimate)					
c. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
2	Regression	271,150	4	67,788	94,994	,000 <sup>c</sup>
	Residual	7,850	11	,714		
	Total	279,000	15			
c. Predictors: (Constant), GDP growth (annual %), Central government debt, total (% of GDP), Inflation, consumer prices (annual %), Unemployment, total (% of total labor force) (national estimate)						

Izvor: Izračun autora

### Prilog 9. Prikaz osnovnih podataka o modelu i tablice Anova (Island)

Model Summary <sup>d</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
3	,993 <sup>c</sup>	,986	,981	,626	2,223
c. Predictors: (Constant), Current account balance (BoP, current US\$), GDP per capita (current US\$), Central government debt, total (% of GDP), Inflation, consumer prices (annual %)					
d. Dependent Variable: Kreditni rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
3	Regression	297,130	4	74,282	189,683	,000 <sup>d</sup>
	Residual	4,308	11	,392		
	Total	301,438	15			
d. Predictors: (Constant), Current account balance (BoP, current US\$), GDP per capita (current US\$), Central government debt, total (% of GDP), Inflation, consumer prices (annual %)						

Izvor: Izračun autora

### Prilog 10. Prikaz osnovnih podataka o modelu i tablice Anova (Italija)

Model Summary <sup>e</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
4	,950 <sup>d</sup>	,902	,878	,913	2,349
d. Predictors: (Constant), Inflation, consumer prices (annual %), GDP per capita (current US\$), Central government debt, total (% of GDP)					
e. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
4	Regression	92,437	3	30,812	36,972	,000 <sup>e</sup>
	Residual	10,001	12	,833		
	Total	102,438	15			
e. Predictors: (Constant), Inflation, consumer prices (annual %), GDP per capita (current US\$), Central government debt, total (% of GDP)						

Izvor: Izračun autora

**Prilog 11. Prikaz osnovnih podataka o modelu i tablice Anova (Izrael)**

Model Summary <sup>e</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
4	,948 <sup>d</sup>	,898	,883	,177	1,734
d. Predictors: (Constant), GDP growth (annual %), Unemployment, total (% of total labor force) (national estimate)					
e. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
4	Regression	3,594	2	1,797	57,470	,000 <sup>e</sup>
	Residual	,406	13	,031		
	Total	4,000	15			
e. Predictors: (Constant), GDP growth (annual %), Unemployment, total (% of total labor force) (national estimate)						

Izvor: Izračun autora

**Prilog 12. Prikaz osnovnih podataka o modelu i tablice Anova (Japan)**

Model Summary <sup>g</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
6	,580 <sup>f</sup>	,336	,289	,968	,762
f. Predictors: (Constant), GDP per capita (current US\$)					
g. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
6	Regression	6,636	1	6,636	7,085	,019 <sup>g</sup>
	Residual	13,114	14	,937		
	Total	19,750	15			
g. Predictors: (Constant), GDP per capita (current US\$)						

Izvor: Izračun autora

### Prilog 13. Prikaz osnovnih podataka o modelu i tablice Anova (Južna Koreja)

Model Summary <sup>e</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
4	,956 <sup>d</sup>	,913	,900	,489	1,139
d. Predictors: (Constant), GDP per capita (current US\$), Current account balance (BoP, current US\$)					
e. Dependent Variable: kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
4	Regression	32,641	2	16,320	68,243	,000 <sup>e</sup>
	Residual	3,109	13	,239		
	Total	35,750	15			
e. Predictors: (Constant), GDP per capita (current US\$), Current account balance (BoP, current US\$)						

Izvor: Izračun autora

### Prilog 14. Prikaz osnovnih podataka o modelu i tablice Anova (Kanada)

Model Summary <sup>f</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
5	,979 <sup>e</sup>	,958	,952	,385	1,584
e. Predictors: (Constant), GDP per capita (current US\$), Unemployment, total (% of total labor force) (national estimate)					
f. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
5	Regression	44,008	2	22,004	148,231	,000 <sup>f</sup>
	Residual	1,930	13	,148		
	Total	45,938	15			
f. Predictors: (Constant), GDP per capita (current US\$), Unemployment, total (% of total labor force) (national estimate)						

Izvor: Izračun autora

**Prilog 15. Prikaz osnovnih podataka o modelu i tablice Anova (Latvija)**

Model Summary <sup>f</sup>					
5	,944 <sup>e</sup>	,890	,873	,287	2,199
e. Predictors: (Constant), Unemployment, total (% of total labor force) (national estimate), Current account balance (BoP, current US\$)					
f. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
5	Regression	8,680	2	4,340	52,734	,000 <sup>f</sup>
	Residual	1,070	13	,082		
	Total	9,750	15			
f. Predictors: (Constant), Unemployment, total (% of total labor force) (national estimate), Current account balance (BoP, current US\$)						
Izvor: Izračun autora						

**Prilog 16. Prikaz osnovnih podataka o modelu i tablice Anova (Litva)**

Model Summary <sup>f</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
5	,944 <sup>e</sup>	,890	,873	,287	2,199
e. Predictors: (Constant), Unemployment, total (% of total labor force) (national estimate), Current account balance (BoP, current US\$)					
f. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
5	Regression	8,680	2	4,340	52,734	,000 <sup>f</sup>
	Residual	1,070	13	,082		
	Total	9,750	15			
f. Predictors: (Constant), Unemployment, total (% of total labor force) (national estimate), Current account balance (BoP, current US\$)						
Izvor: Izračun autora						

**Prilog 17. Prikaz osnovnih podataka o modelu i tablice Anova (Malta)**

Model Summary <sup>e</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
4	,726 <sup>d</sup>	,527	,454	,603	1,081
d. Predictors: (Constant), GDP per capita (current US\$), Current account balance (BoP, current US\$)					
e. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
4	Regression	5,266	2	2,633	7,231	,008 <sup>e</sup>
	Residual	4,734	13	,364		
	Total	10,000	15			
e. Predictors: (Constant), GDP per capita (current US\$), Current account balance (BoP, current US\$)						

Izvor: Izračun autora

**Prilog 18. Prikaz osnovnih podataka o modelu i tablice Anova (Portugal)**

Model Summary <sup>e</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
4	,977 <sup>d</sup>	,955	,944	1,017	1,799
d. Predictors: (Constant), Current account balance (BoP, current US\$), Inflation, consumer prices (annual %), Unemployment, total (% of total labor force) (national estimate)					
e. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
4	Regression	262,518	3	87,506	84,547	,000 <sup>e</sup>
	Residual	12,420	12	1,035		
	Total	274,937	15			
e. Predictors: (Constant), Current account balance (BoP, current US\$), Inflation, consumer prices (annual %), Unemployment, total (% of total labor force) (national estimate)						

Izvor: Izračun autora

### Prilog 19. Prikaz osnovnih podataka o modelu i tablice Anova (Slovačka)

Model Summary <sup>f</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
5	,866 <sup>e</sup>	,750	,711	,555	2,147
e. Predictors: (Constant), Inflation, consumer prices (annual %), Central government debt, total (% of GDP)					
f. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
5	Regression	11,995	2	5,998	19,468	,000 <sup>f</sup>
	Residual	4,005	13	,308		
	Total	16,000	15			
f. Predictors: (Constant), Inflation, consumer prices (annual %), Central government debt, total (% of GDP)						

Izvor: Izračun autora

### Prilog 20. Prikaz osnovnih podataka o modelu i tablice Anova (Slovenija)

Model Summary <sup>e</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
4	,905 <sup>d</sup>	,820	,792	1,380	1,511
d. Predictors: (Constant), Current account balance (BoP, current US\$), GDP per capita (current US\$)					
e. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
4	Regression	112,671	2	56,335	29,570	,000 <sup>e</sup>
	Residual	24,767	13	1,905		
	Total	137,438	15			
e. Predictors: (Constant), Current account balance (BoP, current US\$), GDP per capita (current US\$)						

Izvor: Izračun autora



### Prilog 21. Prikaz osnovnih podataka o modelu i tablice Anova (Španjolska)

Model Summary <sup>d</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
3	,971 <sup>c</sup>	,944	,923	1,042	2,068
c. Predictors: (Constant), GDP growth (annual %), Inflation, consumer prices (annual %), GDP per capita (current US\$), Central government debt, total (% of GDP)					
d. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
3	Regression	199,999	4	50,000	46,069	,000 <sup>d</sup>
	Residual	11,938	11	1,085		
	Total	211,938	15			
d. Predictors: (Constant), GDP growth (annual %), Inflation, consumer prices (annual %), GDP per capita (current US\$), Central government debt, total (% of GDP)						

Izvor: Izračun autora

### Prilog 22. Prikaz osnovnih podataka o modelu i tablice Anova (Ujedinjeno Kraljevstvo)

Model Summary <sup>f</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
5	,867 <sup>e</sup>	,752	,714	,215	2,325
e. Predictors: (Constant), Inflation, consumer prices (annual %), Current account balance (BoP, current US\$)					
f. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
5	Regression	1,834	2	,917	19,746	,000 <sup>f</sup>
	Residual	,604	13	,046		
	Total	2,438	15			
f. Predictors: (Constant), Inflation, consumer prices (annual %), Current account balance (BoP, current US\$)						

Izvor: Izračun autora

**Prilog 23. Prikaz osnovnih podataka o modelu i tablice Anova (BiH)**

Model Summary <sup>e</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
4	,700 <sup>d</sup>	,490	,377	,412	1,351
d. Predictors: (Constant), Current account balance (BoP, current US\$), GDP growth (annual %)					
e. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
4	Regression	1,471	2	,736	4,331	,048 <sup>c</sup>
	Residual	1,529	9	,170		
	Total	3,000	11			
e. Predictors: (Constant), Current account balance (BoP, current US\$), GDP growth (annual %)						
Izvor: Izračun autora						

**Prilog 24. Prikaz osnovnih podataka o modelu i tablice Anova (Bolivija)**

Model Summary <sup>d</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
3	,996 <sup>c</sup>	,991	,985	,156	2,201
c. Predictors: (Constant), Inflation, consumer prices (annual %), GDP per capita (current US\$), CPIA transparency, accountability, and corruption in the public sector rating (1=low to 6=high), Net financial flows, bilateral (NFL, current US\$)					
d. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
3	Regression	16,400	4	4,100	168,604	,000 <sup>d</sup>
	Residual	,146	6	,024		
	Total	16,545	10			
d. Predictors: (Constant), Inflation, consumer prices (annual %), GDP per capita (current US\$), CPIA transparency, accountability, and corruption in the public sector rating (1=low to 6=high), Net financial flows, bilateral (NFL, current US\$)						
Izvor: Izračun autora						

**Prilog 25. Prikaz osnovnih podataka o modelu i tablice Anova (Brazil)**

Model Summary <sup>e</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
4	,845 <sup>d</sup>	,715	,671	,686	1,674
d. Predictors: (Constant), GDP per capita (current US\$), GDP growth (annual %)					
e. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
4	Regression	15,323	2	7,661	16,289	,000 <sup>e</sup>
	Residual	6,115	13	,470		
	Total	21,438	15			
e. Predictors: (Constant), GDP per capita (current US\$), GDP growth (annual %)						

Izvor: Izračun autora

**Prilog 26. Prikaz osnovnih podataka o modelu i tablice Anova (Bugarska)**

Model Summary <sup>d</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
3	,972 <sup>c</sup>	,946	,926	,504	2,329
c. Predictors: (Constant), Inflation, consumer prices (annual %), Central government debt, total (current LCU), GDP growth (annual %), GDP per capita (current US\$)					
d. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
3	Regression	48,646	4	12,162	47,924	,000 <sup>d</sup>
	Residual	2,791	11	,254		
	Total	51,438	15			
d. Predictors: (Constant), Inflation, consumer prices (annual %), Central government debt, total (current LCU), GDP growth (annual %), GDP per capita (current US\$)						

Izvor: Izračun autora

**Prilog 27. Prikaz osnovnih podataka o modelu i tablice Anova (Egipat)**

Model Summary <sup>f</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
5	,950 <sup>e</sup>	,902	,895	1,036	1,486
e. Predictors: (Constant), GDP per capita (current US\$)					
f. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
5	Regression	138,424	1	138,424	129,079	,000 <sup>f</sup>
	Residual	15,014	14	1,072		
	Total	153,438	15			
f. Predictors: (Constant), GDP per capita (current US\$)						

Izvor: Izračun autora

**Prilog 28. Prikaz osnovnih podataka o modelu i tablice Anova (Ekvador)**

Model Summary <sup>d</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
3	,699 <sup>c</sup>	,488	,360	1,510	,835
c. Predictors: (Constant), Net financial flows, bilateral (NFL, current US\$), Current account balance (BoP, current US\$), GDP per capita (current US\$)					
d. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
3	Regression	26,084	3	8,695	3,814	,039 <sup>d</sup>
	Residual	27,354	12	2,279		
	Total	53,438	15			
d. Predictors: (Constant), Net financial flows, bilateral (NFL, current US\$), Current account balance (BoP, current US\$), GDP per capita (current US\$)						

Izvor: Izračun autora

**Prilog 29. Prikaz osnovnih podataka o modelu i tablice Anova (Filipini)**

Model Summary <sup>e</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
4	,743 <sup>d</sup>	,552	,430	1,382	1,635
d. Predictors: (Constant), Inflation, consumer prices (annual %), Current account balance (BoP, current US\$), GDP per capita (current US\$)					
e. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
4	Regression	25,927	3	8,642	4,525	,027 <sup>e</sup>
	Residual	21,007	11	1,910		
	Total	46,933	14			
e. Predictors: (Constant), Inflation, consumer prices (annual %), Current account balance (BoP, current US\$), GDP per capita (current US\$)						

Izvor: Izračun autora

**Prilog 30. Prikaz osnovnih podataka o modelu i tablice Anova (Honduras)**

Model Summary <sup>e</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
4	,639 <sup>d</sup>	,408	,317	,333	,786
d. Predictors: (Constant), Inflation, consumer prices (annual %), Current account balance (BoP, current US\$)					
e. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
4	Regression	,995	2	,497	4,483	,033 <sup>e</sup>
	Residual	1,443	13	,111		
	Total	2,438	15			
e. Predictors: (Constant), Inflation, consumer prices (annual %), Current account balance (BoP, current US\$)						

Izvor: Izračun autora

**Prilog 31. Prikaz osnovnih podataka o modelu i tablice Anova (Hrvatska)**

Model Summary <sup>e</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
4	,981 <sup>d</sup>	,963	,956	,265	1,895
d. Predictors: (Constant), GDP growth (annual %), Central government debt, total (current LCU)					
e. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
4	Regression	20,085	2	10,042	143,007	,000 <sup>e</sup>
	Residual	,772	11	,070		
	Total	20,857	13			
e. Predictors: (Constant), GDP growth (annual %), Central government debt, total (current LCU)						

Izvor: Izračun autora

**Prilog 32. Prikaz osnovnih podataka o modelu i tablice Anova (Indija)**

Model Summary <sup>e</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
4	,942 <sup>d</sup>	,888	,854	,32634	1,521
d. Predictors: (Constant), GDP growth (annual %), Net financial flows, bilateral (NFL, current US\$), GDP per capita (current US\$)					
e. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
4	Regression	8,435	3	2,812	26,401	,000 <sup>e</sup>
	Residual	1,065	10	,107		
	Total	9,500	13			
e. Predictors: (Constant), GDP growth (annual %), Net financial flows, bilateral (NFL, current US\$), GDP per capita (current US\$)						

Izvor: Izračun autora

### Prilog 33. Prikaz osnovnih podataka o modelu i tablice Anova (Indonezija)

Model Summary <sup>b</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	1,000 <sup>a</sup>	,999	,998	,08740	1,779
a. Predictors: (Constant), GDP growth (annual %), Current account balance (BoP, current US\$), Inflation, consumer prices (annual %), Net financial flows, bilateral (NFL, current US\$), Central government debt, total (current LCU), GDP per capita (current US\$)					
b. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	42,877	6	7,146	935,549	,000 <sup>b</sup>
	Residual	,023	3	,008		
	Total	42,900	9			
b. Predictors: (Constant), GDP growth (annual %), Current account balance (BoP, current US\$), Inflation, consumer prices (annual %), Net financial flows, bilateral (NFL, current US\$), Central government debt, total (current LCU), GDP per capita (current US\$)						

Izvor: Izračun autora

### Prilog 34. Prikaz osnovnih podataka o modelu i tablice Anova (Jamajka)

Model Summary <sup>e</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
4	,937 <sup>d</sup>	,877	,804	,443	,299
d. Predictors: (Constant), GDP growth (annual %), Net financial flows, bilateral (NFL, current US\$), Inflation, consumer prices (annual %)					
e. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
4	Regression	7,019	3	2,340	11,920	,010 <sup>e</sup>
	Residual	,981	5	,196		
	Total	8,000	8			
e. Predictors: (Constant), GDP growth (annual %), Net financial flows, bilateral (NFL, current US\$), Inflation, consumer prices (annual %)						

Izvor: Izračun autora

**Prilog 35. Prikaz osnovnih podataka o modelu i tablice Anova (Jordan)**

Model Summary <sup>f</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
5	,716 <sup>e</sup>	,513	,432	1,235	1,665
e. Predictors: (Constant), GDP growth (annual %), Central government debt, total (% of GDP)					
f. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
5	Regression	19,296	2	9,648	6,325	,013 <sup>f</sup>
	Residual	18,304	12	1,525		
	Total	37,600	14			
f. Predictors: (Constant), GDP growth (annual %), Central government debt, total (% of GDP)						
Izvor: Izračun autora						

**Prilog 36. Prikaz osnovnih podataka o modelu i tablice Anova (Južna Afrika)**

Model Summary <sup>d</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
3	,643 <sup>c</sup>	,414	,323	,924	,861
c. Predictors: (Constant), GDP growth (annual %), Current account balance (BoP, current US\$)					
d. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
3	Regression	7,831	2	3,916	4,583	,031 <sup>d</sup>
	Residual	11,106	13	,854		
	Total	18,938	15			
d. Predictors: (Constant), GDP growth (annual %), Current account balance (BoP, current US\$)						
Izvor: Izračun autora						



**Prilog 37. Prikaz osnovnih podataka o modelu i tablice Anova (Katar)**

Model Summary <sup>d</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
3	,789 <sup>c</sup>	,623	,560	,9337	,673
c. Predictors: (Constant), GDP per capita (current US\$)					
d. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
3	Regression	8,645	1	8,645	9,917	,020 <sup>d</sup>
	Residual	5,230	6	,872		
	Total	13,875	7			
d. Predictors: (Constant), GDP per capita (current US\$)						

Izvor: Izračun autora

**Prilog 38. Prikaz osnovnih podataka o modelu i tablice Anova (Kazahstan)**

Model Summary <sup>e</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
4	,558 <sup>d</sup>	,311	,205	1,730	1,349
d. Predictors: (Constant), Net financial flows, bilateral (NFL, current US\$), GDP per capita (current US\$)					
e. Dependent Variable: kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
4	Regression	17,544	2	8,772	2,932	,089 <sup>e</sup>
	Residual	38,893	13	2,992		
	Total	56,437	15			
e. Predictors: (Constant), Net financial flows, bilateral (NFL, current US\$), GDP per capita (current US\$)						

Izvor: Izračun autora

**Prilog 39. Prikaz osnovnih podataka o modelu i tablice Anova (Kolumbija)**

Model Summary <sup>f</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
5	,885 <sup>e</sup>	,784	,722	,272	1,181
e. Predictors: (Constant), Current account balance (BoP, current US\$), GDP per capita (current US\$)					
f. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
5	Regression	1,881	2	,941	12,701	,005 <sup>f</sup>
	Residual	,519	7	,074		
	Total	2,400	9			
f. Predictors: (Constant), Current account balance (BoP, current US\$), GDP per capita (current US\$)						

Izvor: Izračun autora

**Prilog 40. Prikaz osnovnih podataka o modelu i tablice Anova (Kostarika)**

Model Summary <sup>f</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
5	,566 <sup>e</sup>	,320	,272	,382	,889
e. Predictors: (Constant), GDP per capita (current US\$)					
f. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
4	Regression	1,174	2	,587	4,177	,040 <sup>e</sup>
	Residual	1,826	13	,140		
	Total	3,000	15			
5	Regression	,961	1	,961	6,603	,022 <sup>f</sup>
	Residual	2,039	14	,146		
	Total	3,000	15			
f. Predictors: (Constant), GDP per capita (current US\$)						

Izvor: Izračun autora

**Prilog 41. Prikaz osnovnih podataka o modelu i tablice Anova (Kuba)**

Model Summary <sup>c</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
2	,572 <sup>b</sup>	,327	,279	,290	,817
b. Predictors: (Constant), GDP per capita (current US\$)					
c. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
2	Regression	,573	1	,573	6,808	,021 <sup>c</sup>
	Residual	1,177	14	,084		
	Total	1,750	15			
c. Predictors: (Constant), GDP per capita (current US\$)						

Izvor: Izračun autora

**Prilog 42. Prikaz osnovnih podataka o modelu i tablice Anova (Kuvajt)**

Model Summary <sup>b</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,933 <sup>a</sup>	,870	,822	,799	1,087
a. Predictors: (Constant), GDP growth (annual %), Current account balance (BoP, current US\$), Inflation, consumer prices (annual %), GDP per capita (current US\$)					
b. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	46,913	4	11,728	18,367	,000 <sup>b</sup>
	Residual	7,024	11	,639		
	Total	53,937	15			
b. Predictors: (Constant), GDP growth (annual %), Current account balance (BoP, current US\$), Inflation, consumer prices (annual %), GDP per capita (current US\$)						

Izvor: Izračun autora

**Prilog 43. Prikaz osnovnih podataka o modelu i tablice Anova (Libanon)**

Model Summary <sup>d</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
3	,939 <sup>c</sup>	,882	,861	,333	,958
c. Predictors: (Constant), GDP growth (annual %), GDP per capita (current US\$)					
d. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
3	Regression	9,139	2	4,570	41,268	,000 <sup>d</sup>
	Residual	1,218	11	,111		
	Total	10,357	13			
d. Predictors: (Constant), GDP growth (annual %), GDP per capita (current US\$)						

Izvor: Izračun autora

**Prilog 44. Prikaz osnovnih podataka o modelu i tablice Anova (Mađarska)**

Model Summary <sup>f</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
5	,980 <sup>e</sup>	,961	,958	,555	1,396
e. Predictors: (Constant), Central government debt, total (% of GDP)					
f. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
5	Regression	105,439	1	105,439	342,388	,000 <sup>f</sup>
	Residual	4,311	14	,308		
	Total	109,750	15			
f. Predictors: (Constant), Central government debt, total (% of GDP)						

Izvor: Izračun autora

**Prilog 45. Prikaz osnovnih podataka o modelu i tablice Anova (Meksiko)**

Model Summary <sup>e</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
4	,881 <sup>d</sup>	,776	,741	,205	1,688
d. Predictors: (Constant), Inflation, consumer prices (annual %), Current account balance (BoP, current US\$)					
e. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
4	Regression	1,890	2	,945	22,458	,000 <sup>e</sup>
	Residual	,547	13	,042		
	Total	2,438	15			
e. Predictors: (Constant), Inflation, consumer prices (annual %), Current account balance (BoP, current US\$)						

Izvor: Izračun autora

**Prilog 46. Prikaz osnovnih podataka o modelu i tablice Anova (Moldavija)**

Model Summary <sup>f</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
5	,887 <sup>e</sup>	,787	,754	1,023	1,600
e. Predictors: (Constant), Current account balance (BoP, current US\$), GDP per capita (current US\$)					
f. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
5	Regression	50,329	2	25,164	24,039	,000 <sup>f</sup>
	Residual	13,609	13	1,047		
	Total	63,938	15			
f. Predictors: (Constant), Current account balance (BoP, current US\$), GDP per capita (current US\$)						

Izvor: Izračun autora

**Prilog 47. Prikaz osnovnih podataka o modelu i tablice Anova (Oman)**

Model Summary <sup>d</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
3	,971 <sup>c</sup>	,943	,919	,447	1,938
c. Predictors: (Constant), Central government debt, total (% of GDP), Inflation, consumer prices (annual %), GDP per capita (current US\$)					
d. Dependent Variable: kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
3	Regression	23,328	3	7,776	38,908	,000 <sup>d</sup>
	Residual	1,399	7	,200		
	Total	24,727	10			
d. Predictors: (Constant), Central government debt, total (% of GDP), Inflation, consumer prices (annual %), GDP per capita (current US\$)						

Izvor: Izračun autora

**Prilog 48. Prikaz osnovnih podataka o modelu i tablice Anova (Pakistan)**

Model Summary <sup>f</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
5	,523 <sup>e</sup>	,274	,222	,904	,696
e. Predictors: (Constant), GDP growth (annual %)					
f. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
5	Regression	4,309	1	4,309	5,273	,038 <sup>f</sup>
	Residual	11,441	14	,817		
	Total	15,750	15			
f. Predictors: (Constant), GDP growth (annual %)						

Izvor: Izračun autora

**Prilog 49. Prikaz osnovnih podataka o modelu i tablice Anova (Panama)**

Model Summary <sup>d</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
3	,957 <sup>c</sup>	,916	,895	,287	1,718
c. Predictors: (Constant), GDP per capita (current US\$), Inflation, consumer prices (annual %), Current account balance (BoP, current US\$)					
d. Dependent Variable: V9					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
3	Regression	10,762	3	3,587	43,566	,000 <sup>d</sup>
	Residual	,988	12	,082		
	Total	11,750	15			
d. Predictors: (Constant), GDP per capita (current US\$), Inflation, consumer prices (annual %), Current account balance (BoP, current US\$)						

Izvor: Izračun autora

**Prilog 50. Prikaz osnovnih podataka o modelu i tablice Anova (Paragvaj)**

Model Summary <sup>f</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
5	,666 <sup>e</sup>	,444	,404	1,497	,502
e. Predictors: (Constant), GDP per capita (current US\$)					
f. Dependent Variable: V9					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
5	Regression	25,069	1	25,069	11,188	,005 <sup>f</sup>
	Residual	31,369	14	2,241		
	Total	56,437	15			
f. Predictors: (Constant), GDP per capita (current US\$)						

Izvor: Izračun autora

**Prilog 51. Prikaz osnovnih podataka o modelu i tablice Anova (Peru)**

Model Summary <sup>f</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
5	,854 <sup>e</sup>	,729	,651	,726	1,516
e. Predictors: (Constant), Central government debt, total (% of GDP), GDP per capita (current US\$)					
f. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
5	Regression	9,912	2	4,956	9,406	,010 <sup>f</sup>
	Residual	3,688	7	,527		
	Total	13,600	9			
f. Predictors: (Constant), Central government debt, total (% of GDP), GDP per capita (current US\$)						

Izvor: Izračun autora

**Prilog 52. Prikaz osnovnih podataka o modelu i tablice Anova (Rumunjska)**

Model Summary <sup>e</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
4	,984 <sup>d</sup>	,969	,961	,444	1,820
d. Predictors: (Constant), Inflation, consumer prices (annual %), Central government debt, total (% of GDP), GDP per capita (current US\$)					
e. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
4	Regression	73,569	3	24,523	124,270	,000 <sup>e</sup>
	Residual	2,368	12	,197		
	Total	75,938	15			
e. Predictors: (Constant), Inflation, consumer prices (annual %), Central government debt, total (% of GDP), GDP per capita (current US\$)						

Izvor: Izračun autora



**Prilog 53. Prikaz osnovnih podataka o modelu i tablice Anova (Rusija)**

Model Summary <sup>g</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
6	,934 <sup>f</sup>	,872	,863	,837	1,315
f. Predictors: (Constant), Central government debt, total (% of GDP)					
g. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
6	Regression	62,231	1	62,231	88,881	,000 <sup>g</sup>
	Residual	9,102	13	,700		
	Total	71,333	14			
g. Predictors: (Constant), Central government debt, total (% of GDP)						

Izvor: Izračun autora

**Prilog 54. Prikaz osnovnih podataka o modelu i tablice Anova (Tunis)**

Model Summary <sup>e</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
4	,961 <sup>d</sup>	,924	,898	,120	2,229
d. Predictors: (Constant), Central government debt, total (% of GDP), Current account balance (BoP, current US\$), GDP per capita (current US\$)					
e. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
4	Regression	1,563	3	,521	36,316	,000 <sup>e</sup>
	Residual	,129	9	,014		
	Total	1,692	12			
e. Predictors: (Constant), Central government debt, total (% of GDP), Current account balance (BoP, current US\$), GDP per capita (current US\$)						

Izvor: Izračun autora

**Prilog 55. Prikaz osnovnih podataka o modelu i tablice Anova (Turska)**

Model Summary <sup>d</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
3	,995 <sup>c</sup>	,990	,976	,203	,116
c. Predictors: (Constant), GDP growth (annual %), Inflation, consumer prices (annual %), Current account balance (BoP, current US\$), GDP per capita (current US\$)					
d. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
3	Regression	11,752	4	2,938	71,506	,003 <sup>d</sup>
	Residual	,123	3	,041		
	Total	11,875	7			
d. Predictors: (Constant), GDP growth (annual %), Inflation, consumer prices (annual %), Current account balance (BoP, current US\$), GDP per capita (current US\$)						

Izvor: Izračun autora

**Prilog 56. Prikaz osnovnih podataka o modelu i tablice Anova (Ukrajina)**

Model Summary <sup>e</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
4	,969 <sup>d</sup>	,939	,924	,530	1,942
d. Predictors: (Constant), Net financial flows, bilateral (NFL, current US\$), Current account balance (BoP, current US\$), Central government debt, total (% of GDP)					
e. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
4	Regression	52,069	3	17,356	61,832	,000 <sup>e</sup>
	Residual	3,368	12	,281		
	Total	55,438	15			
e. Predictors: (Constant), Net financial flows, bilateral (NFL, current US\$), Current account balance (BoP, current US\$), Central government debt, total (% of GDP)						

Izvor: Izračun autora

**Prilog 57. Prikaz osnovnih podataka o modelu i tablice Anova (Urugvaj)**

Model Summary <sup>d</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
3	,965 <sup>c</sup>	,932	,913	,801	2,463
c. Predictors: (Constant), GDP growth (annual %), GDP per capita (current US\$), Central government debt, total (% of GDP)					
d. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
3	Regression	96,547	3	32,182	50,195	,000 <sup>d</sup>
	Residual	7,053	11	,641		
	Total	103,600	14			
d. Predictors: (Constant), GDP growth (annual %), GDP per capita (current US\$), Central government debt, total (% of GDP)						

Izvor: Izračun autora

**Prilog 58. Prikaz osnovnih podataka o modelu i tablice Anova (Venezuela)**

Model Summary <sup>d</sup>					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
3	,834 <sup>c</sup>	,695	,603	,836	1,450
c. Predictors: (Constant), GDP per capita (current US\$), Current account balance (BoP, current US\$), Inflation, consumer prices (annual %)					
d. Dependent Variable: Kr rejting					

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
3	Regression	15,934	3	5,311	7,594	,006 <sup>d</sup>
	Residual	6,994	10	,699		
	Total	22,929	13			
d. Predictors: (Constant), GDP per capita (current US\$), Current account balance (BoP, current US\$), Inflation, consumer prices (annual %)						

Izvor: Izračun autora