Procjena krivulje prinosa korporativnih obveznica na hrvatskom financijskom tržištu

Vrdoljak, Ante - Toni

Professional thesis / Završni specijalistički

2014

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:124:394319

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

zir.nsk.hr

UNIVERSITY OF SPLIT

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET U SPLITU
Poslijediplomski specijalistički studij poslovne ekonomije
Financijski menadžment

Ante – Toni Vrdoljak

PROCJENA KRIVULJE PRINOSA KORPORATIVNIH OBVEZNICA NA HRVATSKOM FINANCIJSKOM TRŽIŠTU

ZAVRŠNI RAD

Mentor: Prof.dr.sc. Zdravka Aljinović

Split, srpanj 2014.

PODACI I INFORMACIJE O SPECIJALIZANTU I ZAVRŠNOM RADU

Ime i prezime: Ante – Toni Vrdoljak

Datum i mjesto rođenja: 21.9.1984., Split

Naziv završenog diplomskog studija: Diplomirani inženjer matematike, smjer: Financijska i poslovna matematika

PODACI O ZAVRŠNOM RADU

1. Naslov završnog rada: Procjena krivulje prinosa korporativnih obveznica na hrvatskom financijskom tržištu

2. Područje: Društvene znanosti

3. Polje: Ekonomija

4. Smjer: Financijski menadžment

POVJERENSTVA, OCJENA I OBRANA RADA

1. Povjerenstvo za ocjenu teme i dispozicije završnog rada:

1. Prof. dr. sc. Zdravka Aljinović, predsjednica povjerenstva
2. Doc. dr. sc. Branka Marasović, članica
3. Doc. dr. sc. Roberto Ercegovac, član

2. Datum prihvaćanja teme: 13. svibnja 2014.

3. Mentor: Prof. dr. sc. Zdravka Aljinović

4. Povjerenstvo za ocjenu rada:

1. Doc. dr. sc. Branka Marasović, predsjednica
2. Prof. dr. sc. Zdravka Aljinović, mentorica
3. Doc. dr. sc. Roberto Ercegovac, član

5. Povjerenstvo za obranu rada:

1. Doc. dr. sc. Branka Marasović, predsjednica
2. Prof. dr. sc. Zdravka Aljinović, mentorica
3. Doc. dr. sc. Roberto Ercegovac, član

6. Datum i mjesto obrane rada: 16. srpnja 2014., Split

SADRŽAJ

1. UVOD.....5

1.1. Problem istraživanja.....5

1.2. Predmet istraživanja.....9

1.3. Istraživačke hipoteze.....9

1.4. Svrha i ciljevi istraživanja.....10

1.5. Metode istraživanja.....10

1.6. Struktura završnog rada.....11

2.VREMENSKA STRUKTURA KAMATNIH STOPA – KRIVULJA PRINOSA.....13

2.1. Pojam vremenske strukture kamatnih stopa.....13

2.2.Oblici krivulje prinosa.....15

2.3. Implicitna buduća kamatna stopa(forward).....19

2.4. Teorije vremenske strukture kamatnih stopa.....20

2.4.1. Teorija očekivanja.....21

2.4.2. Teorija segmentacije tržišta.....24

2.4.3. Teorija preferiranja likvidnosti.....26

2.5. Uloga krivulje prinosa.....29

2.5.1. Mikroekonomski aspekt.....29

2.5.2. Makroekonomski aspekt.....31

3. PARAMETRIJSKI MODELI ZA PROCJENU KRIVULJE PRINOSA.....33

3.1. Nelson – Siegelov model.....33

3.2. Svenssonov model.....35

3.3. Diebold-Li faktorizacija.....37

4. HRVATSKO FINANCIJSKO TRŽIŠTE DUŽNIČKIH VRIJEDNOSNIH PAPIRA.....39

4.1. Tržište javnog duga u Republici Hrvatskoj.....41

4.1.1. Primarno tržište javnog duga u Republici Hrvatskoj.....41

4.1.2. Sekundarno tržište javnog duga u Republici Hrvatskoj.....43

4.1.3. Pregled i razvoj tržišta javnog duga u Republici Hrvatskoj.....45

4.2. Tržište korporativnog duga u Republici Hrvatskoj.....52

5. IZRAČUN KRIVULJE PRINOSA.....58

5.1. Formiranje ulaznih podataka i izračun krivulje prinosa za RH na određeni datum.....58

5.1.1. Statistička značajnost parametara primijenjenog modela.....65

5.2. Formiranje ulaznih podataka i izračun krivulje prinosa korporativnih obveznica hrvatskog financijskog tržišta.....67

5.2.1. Statistička značajnost parametara primijenjenog modela.....72

5.3. Usporedba krivulje prinosa za RH i krivulje prinosa korporativnih obveznica hrvatskog financijskog tržišta.....74

5.4. Krivulje prinosa drugih zemalja i usporedba.....77

6. ZAKLJUČAK.....80

LITERATURA.....82

POPIS SLIKA.....87

POPIS TABLICA.....88

PRILOZI.....89

SAŽETAK.....93

1.UVOD

1.1. Problem istraživanja

Vremenska struktura kamatnih stopa (the term structure of interest rates) je pojam kojim se označava veza između stope prinosa, odnosno kamatne stope od određene vrste vrijednosnih papira i njihovog vremena dospijeća.[1] Krivulja prinosa (yield curve) je grafički prikaz vremenske strukture kamatnih stopa i razlikujemo četiri moguća oblika: pravilni (rastući), inverzni (padajući), ravni te neravni oblik. Budući da je rastući oblik krivulje prinosa najčešći, takva se krivulja naziva pravilna ili normalna.
Oblik krivulje prinosa ima veliki učinak na financijska tržišta i na ponašanje financijskih posrednika. Rizik krivulje prinosa jest rizik kojem je kreditna institucija izložena zbog promjene oblika i nagiba krivulje prinosa.[2]
Cijeli niz aktivnosti na financijskim tržištima je zapravo uvjetovan odnosom između kamatnih stopa i vremena dospijeća. Posrednici će, nastojeći maksimizirati svoj profit, voditi računa o razlici između kratkoročnih i dugoročnih kamatnih stopa. U uvjetima kada se očekuje normalna krivulja prinosa, posrednici emitiraju kratkoročne a kupuju dugoročne vrijednosne papire. Moguća inverzija krivulje prinosa njihove će očekivane profite pretvoriti u gubitke.[3]

Analiza vremenske strukture kamatnih stopa najčešće se provodi za bezrizične vrijednosne papire, pa u tom smislu najveću sigurnost pružaju državne obveznice, budući da je država neograničeno likvidna s obzirom na svoje domicilne porezne obveznike.[4] Krivulja prinosa, kao slika odnosa između prinosa na obveznice različitih dospijeća, pruža način za razumijevanje zajedničke procjene tržišta u budućnosti, odnosno hoće li ekonomija biti jaka ili pak slaba.[5] Konstrukcija krivulje prinosa korisna je i za otkrivanje vrijednosnih papira koji imaju previsoku ili prenisku cijenu.

---

[1] Aljinović, Z., Marasović, B.: *Matematički modeli u analizi razvoja hrvatskog financijskog tržišta*, Ekonomski fakultet u Splitu, 2012., str. 27.
[2] http://www.hnb.hr/propisi/odluke-nadzor-kontrola/odluke-zoki-ozujak-2010/h-odluka-upravljanje-kamatnim-rizikom-u-knjizi-banke-37-2012.pdf (12.3.2014.)
[3] Aljinović, Z., Marasović, B., Šego, B.: *Financijsko modeliranje*, II. Izmijenjeno i dopunjeno izdanje, Ekonomski fakultet u Splitu, 2011., str.272
[4] Tomić-Plazibat, N., Aljinović, Z., Marasović, B.: *Matematički modeli u financijskom upravljanju*, Ekonomski fakultet u Splitu, 2006., str.41
[5] Aljinović, Z., Marasović, B.: *Matematički modeli u analizi razvoja hrvatskog financijskog tržišta*, Split: Ekonomski fakultet, 2012., str. 27.

Na hrvatskom financijskom tržištu izdaju se dvije vrste obveznica i trezorskih zapisa: kunski i oni uz valutnu klauzulu. Kunskim izdanjem se doprinosi razvoju kunske krivulje prinosa dok se za obveznice uz valutnu klauzulu očekuje da će zadovoljiti povećanu potražnju za devizama na tržištu pa će imati povoljan učinak na kretanje tečaja.

Krivulja prinosa se redovito objavljuje na dnevnoj bazi u velikom broju zemalja, međutim Hrvatska nije jedna među njima. Hrvatska, naime, nema još uvijek službeno objavljenu krivulju prinosa od strane HNB-a.[6]
Problem u Hrvatskoj je njena prevelika euroizacija, odnosno zaduživanje i kreditiranje u eurima uslijed nepovjerenja u domaću valutu. Za uspješan proces deeuroizacije zemlje iznimno je važno da se javni sektor više zadužuje u domaćoj valuti, po mogućnosti češće, u manjim iznosima, i sa što je moguće raznolikijim rokovima dospijeća, što bi pomoglo uspostavljanju referentne krivulja prinosa za domaću valutu.[7] Slaba trgovina državnim obveznicama i trezorskim zapisima na hrvatskom sekundarnom tržištu dodatni je problem pri izradi krivulje prinosa.
Uz stabilne krivulje prinosa državnih obveznica lakše bi se određivale cijene ostalih instrumenata na tržištu kapitala poput korporativnih obveznica i ostalih dužničkih financijskih instrumenata.[8]

Korporacijske ili korporativne obveznice izdaju velike i uspješne kompanije u cilju prikupljanja potrebnih novčanih sredstava, u slučaju kada je novac na tržištu kapitala jeftiniji i pristupačniji nego putem klasičnih bankarskih kredita. Korporativne obveznice, u pravilu, nose veću kamatnu stopu od državnih i municipalnih, ali i veći rizik povrata uloženih sredstava. Kamatna stopa korporativne obveznice određuje se na način da se na referentnu kamatnu stopu (prinos državnih obveznica) sličnog vremena dospijeća[9] doda premija rizika koja indicira kreditni rizik izdavatelja ili grane industrije kojoj izdavatelj pripada.

[6] Ibidem, str.28.
[7] Galac, T.: *Globalna kriza i kreditna euroizacija u Hrvatskoj*, Hrvatska narodna banka, Istraživanja I-33, 2011., str. 5
[8] http://web.efzg.hr/dok/FIN//Primorac.pdf (12.3.2014.)
[9] Najčešće se za referentnu kamatnu stopu koristi prinos petogodišnjih državnih obveznica (prema Prospektima izdanja korporativnih obveznica dostupnim na www.zse.hr)

Hrvatsko tržište korporativnih obveznica odlikuje mala kapitalizacija[10], čak i u odnosu na skromnu ukupnu kapitalizaciju hrvatskoga tržišta kapitala te nedovoljna likvidnost. Zbog nepostojanja dugoročne krivulje prinosa i odsutnosti dovoljne likvidnosti financijskog tržišta postoji problem vrednovanja dugoročne imovine s fiksnim prinosom. Nadalje, standardni računovodstveni principi nalažu primjenu računovodstva fer vrijednosti kod knjiženja i usklađivanja vrijednosti trgovačkog portfelja ili portfelja raspoloživog za prodaju[11], tj. kod revalorizacije financijske imovine. Velika oscilacija cijene, izrazita volatilnost prinosa, mali volumeni trgovanja i rijetkost transakcija upućuju na zaključak da transakcijska cijena ne može izražavati fer vrijednost niti jedne korporativne obveznice s hrvatskog financijskog tržišta. U tom slučaju pribjegava se modelskom izrazu fer vrijednosti koja se ne može utvrditi bez bezrizične tržišne kamatne stope (prinos državnih obveznica) i premije kreditnog rizika (najčešće izražene u baznim poenima).

S druge strane, većina vrijednosnih papira s fiksnom kamatnom stopom, koji povlače za sobom kreditni rizik, donosi viši prinos nego državne obveznice.
Na hrvatskom financijskom tržištu djeluju stambene štedionice, mirovinski i investicijski fondovi, osiguravajuća i mirovinska osiguravajuća društva kao potencijalni investitori. Njihova obveza je i ulaganje u dužničke vrijednosne papire ili instrumente tržišta čiji je izdavatelj ili za koje jamči RH ili jedinice lokalne samouprave, zatim vrijednosne papire s bankarskom garancijom i one čiji je izdavatelj HBOR i HNB.
Kako su hrvatske korporativne obveznice dominantno srednjoročne i dugoročne obveznice, ulaganje u obveznice onih korporacija zadovoljavajućeg kreditnog rizika se nameće kao logičan izbor. Dosad su u korporativne obveznice najviše ulagale banke i fondovi te osiguravajuća društva.[12] Preduvjet za uključivanje korporativnih obveznica u optimalni portfelj je postojanje kvalitetne krivulje prinosa korporativnih obveznica.

Stoga se kao problem istraživanja postavlja pitanje da li je moguće procijeniti i konstruirati kvalitetnu krivulju prinosa korporativnih obveznica na hrvatskom financijskom tržištu.

[10] Prema izračunu autora ukupan volumen emitiranih korporativnih obveznica za siječanj 2014.godine iznosi 3,23 milijarde kuna. Izvori: *http://www.hnb.hr/publikac/bilten/arhiv/bilten-199/hbilt199.pdf* i podaci o korporativnim obveznicama s Uređenog tržišta Zagrebačke burze *www.zse.hr* (23.2.2014.)
[11] Prema Ercegovac, R., Kundid, A.: *Modelski pristup fer vrijednosti korporativnih obveznica u Republici Hrvatskoj*, Računovodstvo i financije LVI(6), 2010., str.76-80
[12] Prema http://www.vecernji.hr/kompanije-i-trzista/fondovi-su-prestali-objavljivati-detaljne-popise-u-sto-i-kako-ulazu-417735 (12.3.2014.); http://e-lib.efst.hr/2011/7020426.pdf; http://www.business.hr/kompanije/nexe-u-najvecem-korporativnom-izdanju-obveznica-u-povijesti-hrvatske (12.3.2014.) i http://limun.hr/main.aspx?id=554098 (12.3.2014.)

Za procjenu krivulje prinosa središnje banke koriste različite modele. U većini stranih zemalja prevladavaju Svenssonov i Nelson-Siegelov (N-S) model.

Nelson-Siegelov model je iznimno popularan u praksi, kako kod pojedinačnih investitora tako i kod središnjih banki. Neke od prednosti ovog modela su: jednostavan je i stabilan za procjenu, poprilično je fleksibilan i vrlo dobro odgovara za procjenu prinosa više obveznica ili jedne obveznice i za vremenske serije prinosa, za velik broj zemalja i vremenskih perioda i za različite klase obveznica te ima dobru sposobnost predviđanja.[13]

Drugi također poprilično korišten model je Svenssonov model. Svenssonov model je prošireni Nelson-Siegelov model, koji nudi zadovoljavajuću preciznost prilagodbe i glatki oblik krivulje periodičkih renti. Međutim, model ima neke slabosti: ograničena mu je mogućnost prilagodbe nepravilnim oblicima krivulje prinosa, ima tendenciju uzimanja ekstremnih vrijednosti na dnu krivulje i relativno snažnu ovisnost o procjenama u različitim ili čak i nesusjednim segmentima krivulje prinosa.[14]

Zbog navedenih slabosti Svenssonovog modela za primjenu na hrvatskom financijskom tržištu prednost se daje Nelson-Siegelovom modelu.

[13] Christensen H. E. J. , Diebold X. F. , Rudebusch D. G. :The affine arbitrage-free class of Nelson-Siegel term structure models, Working Paper Series 2007-20, Federal Reserve Bank of San Francisco, 2007. , str. 2.
[14] Marciniak M. : Yield Curve Estimation at the National Bank of Poland, National Bank of Poland working paper N° 47, 2006. , str. 58.

1.2. Predmet istraživanja

Predmet istraživanja proizlazi iz uočenog problema istraživanja. Istražit će se mogućnost konstrukcije validne krivulje prinosa korporativnih obveznica na hrvatskom financijskom tržištu pomoću Nelson-Siegelova modela. Budući da je konstrukcija krivulje prinosa korporativnih obveznica usko vezana uz konstrukciju krivulje prinosa hrvatskih državnih obveznica, trezorskih i blagajničkih zapisa, predmetom istraživanja postaje i mogućnost procjene validne krivulje prinosa hrvatskih državnih obveznica, trezorskih i blagajničkih zapisa.
Istražit će se mogući oblici rezultirajuće krivulje prinosa i ukazati na njihovo značenje i mogućnosti korištenja.
Ispitat će se i signifikantnost parametara modela primijenjenog N-S modela u procjeni krivulje.

1.3. Istraživačke hipoteze

Nakon što je opisana problematika i predmet istraživanja moguće je postaviti hipoteze rada.

Temeljna radna hipoteza:

Moguća je procjena validne krivulje prinosa korporativnih obveznica na hrvatskom financijskom tržištu.

Pomoćne hipoteze:

1) *Moguće je procijeniti krivulju prinosa državnih obveznica, trezorskih i blagajničkih zapisa na hrvatskom financijskom tržištu.*

2) *Parametrijski Nelson-Siegelov model je valjan model za procjenu krivulje prinosa državnih obveznica, trezorskih i blagajničkih zapisa na hrvatskom financijskom tržištu, tj. svi parametri Nelson-Siegelova modela prilikom procjene krivulje prinosa državnih obveznica, trezorskih i blagajničkih zapisa na hrvatskom financijskom tržištu su statistički značajni.*

1.4. Svrha i ciljevi istraživanja

U skladu s prethodno navedenim određeni su temeljni ciljevi i svrha rada.
Ponajprije je cilj procijeniti i konstruirati krivulju prinosa hrvatskih obveznica, trezorskih i blagajničkih zapisa te ustanoviti da li ona reprezentativna, odnosno može li ona prikazati stvarno stanje tržišta dužničkim vrijednosnim papirima u Republici Hrvatskoj te ima li prognostičku težinu. Cilj je i doprinijeti boljem razumijevanju samog pojma krivulje prinosa te važnosti njene konstrukcije za sudionike financijskih tržišta, kao i upoznavanju s modelima za njezinu procjenu.
Sljedeći cilj je procjena krivulje prinosa portfelja korporativnih obveznica koja je potrebna kako investitorima tako i kod knjiženja i usklađivanja vrijednosti trgovačkog portfelja ili portfelja raspoloživog za prodaju, tj. kod revalorizacije financijske imovine koja se vodi po principu fer vrijednosti, odnosno modelskom pristupu zbog neefikasnosti financijskih tržišta.
Cilj rada je detaljno prikazati sve korake potrebne za konstrukciju krivulje prinosa od formiranja ulaznih podataka s burze, tržišta novca i baze Reutersa potrebnih za Nelson-Siegelov model sve do odgovarajuće provjere signifikantnosti parametara korištenog modela.
Budući da ne postoji službeno objavljena krivulja prinosa od strane HNB-a, a i općenito je literatura iz ovog područja kod nas malobrojna, s tim da literature za procjenu krivulje prinosa korporativnih obveznica gotovo da i nema, doprinos ovog rada je i obogaćivanje postojeće literature, s ciljem da možda doprinese rastućem interesu za podacima ovog tipa s hrvatskog financijskog tržišta.
Ovaj rad će indirektno dati širu sliku o postojećem stanju na hrvatskom financijskom tržištu.

1.5. Metode istraživanja

Obzirom na problematiku, ciljeve rada i postavljene hipoteze koristit će se metode primjerene istraživanju u društvenim znanostima.

U teorijskom dijelu rada, posebno u dijelu vezanom uz teorije vremenske strukture kamatnih stopa koristit će se metode deskripcije i klasifikacije te metoda analize u kontekstu raščlanjivanja složenih teorijskih pojmova.

Prilikom prikaza hrvatskog tržišta dužničkih vrijednosnih papira koristit će se metode analize, sinteze, klasifikacije i deskripcije.
U empirijskom dijelu rada prilikom prikaza rezultata i objašnjenju istih koristit će se metoda deskripcije. Komparativna metoda kao i metoda analize koristit će se prilikom usporedbe prinosa korporativnih obveznica hrvatskog tržišta u odnosu na primjere sa ostalih tržišta. Prilikom donošenja zaključaka koristit će se induktivna i deduktivna metoda.
U radu će se također koristiti i metoda konkretizacije i generalizacije kako bi se određeni pojmovi približili stvarnosti.
Pri izračunu različitih parametara (posebice temeljenih na nizu numeričkih povijesnih podataka) koristit će se različite statističke i kvantitativne metode.
U svrhu bolje preglednosti i lakše usporedivosti podaci će se prikazati tablično i grafički.
Pri analizi podataka koristit će se programski alat Statistica i Microsoft Excel.

1.6. Struktura završnog rada

Rad je koncipiran na način da se sastoji od pet poglavlja, a u nastavku je prikazan kratak sadržaj svakog poglavlja.

U uvodnom dijelu rada definira se problematika i daje kratak opis predmeta istraživanja, potom slijedi postavljanje hipoteza te se definiraju svrha i ciljevi rada. Navest će se i znanstveno – istraživačke metode koje će se koristiti u radu i doprinos rada. Na kraju poglavlja daje se kratak prikaz strukture rada.
U drugom poglavlju definirat će se krivulja prinosa te njeni osnovni pojmovi. Također će se dati pregled teorija vremenske strukture kamatnih stopa, odnosno krivulje prinosa. U posljednjem dijelu bit će opisan značaj krivulje prinosa kroz mikroekonomski i makroekonomski aspekt.
Treće poglavlje je posvećeno parametrijskim modelima procjene krivulje prinosa. Detaljno će se opisati pretpostavke modela, parametri te prednosti i nedostaci Nelson-Siegelova modela kao i njegovih proširenja Svenssonova modela i Diebold-Li faktorizacije.
Četvrto poglavlje daje detaljan pregled dužničkih vrijednosnih papira te ističe karakteristike tržišta državnih vrijednosnih papira i korporativnih obveznica u Republici Hrvatskoj.

U petom poglavlju opisat će se i zorno prikazati primjena Nelson-Siegelovog modela u aproksimaciji krivulje prinosa državnih obveznica, trezorskih i blagajničkih zapisa na određeni datum kad je zabilježena dostatna trgovina te konstrukcija krivulje prinosa izabranog portfelja korporativnih obveznica. Provjerit će se signifikantnost parametara primijenjenog modela i značajnost samog modela u konstrukciji obje krivulje prinosa. Također, međusobno će se usporediti rezultirajuće krivulje, kao i s krivuljama drugih zemalja.

U zaključku će se sintetizirati svi rezultati provedenih istraživanja, analiza i usporedbi te njihova implikacija na definiranu problematiku, ciljeve rada i postavljene hipoteze.

2. VREMENSKA STRUKTURA KAMATNIH STOPA - KRIVULJA PRINOSA

2. 1. Pojam vremenske strukture kamatnih stopa

Vremenska struktura kamatnih stopa (the term structure of interest rates) je pojam kojim se označava veza između stope prihoda, odnosno kamatne stope od određene vrste vrijednosnih papira i njihovog vremena dospijeća.[15] Kamatne stope se promatraju samo u zavisnosti o vremenu dospijeća dok se utjecaj ostalih čimbenika izolira.
Rizik da li će o dospijeću dug biti vraćen spada među ostale čimbenike. Stoga se analiza vremenske strukture kamatnih stopa najčešće provodi za bezrične vrijednosne papire, gdje pridjev „bezrizični" znači siguran povrat novca uloženog u kupovinu vrijednosnog papira uvećanog za kamate.[16] Najveću sigurnost pružaju državne obveznice jer je država neograničeno likvidna s obzirom na svoje domicilne porezne obveznike.

Promatranje stope prinosa s obzirom na vrijeme dospijeća nije jednako prikladno za sve vrste obveznica. Kod obveznica s kuponima (višekratno isplative obveznica), tzv. klasičnih obveznica, vrijeme dospijeća označava samo trenutak konačne otplate nominalnog duga, a ne i ostale isplate, kao na primjer godišnje ili polugodišnje kamate. Kod ovih obveznica posebnu pažnju treba obratiti na prinos koji se ostvaruje mogućim reinvestiranjem periodično isplaćenih kamata. Koncept vremenske strukture kamatnih stopa je najprikladniji za takozvane nul-kupon obveznice (obveznice bez kupona ili jednokratno isplative obveznice) kod kojih se pripadajuća kamata ne isplaćuje periodično nego se kamata obračunava, odnosno nalazi u diskontiranom tečaju, tj. cijeni nul-kupon obveznice. Sve navedene poželjne karakteristike ima jedna posebna vrsta kratkoročnih vrijednosnih papira: blagajnički ili trezorski zapisi koje izdaju ministarstva financija, državne agencije ili središnje banke, pa se stoga smatraju bezrizičnima. Cijena im je pri prodaji niža od nominalne, a o dospijeću isplaćuje se nominalna vrijednost upisana u zapisu. Skoro pa nikad se ne prodaju s kamatnim kuponom, tj. uz prinos kroz vrijeme. Uobičajeno vrijeme dospijeća im je 91 dan ili 182 dana, dok se blagajnički zapisi američke vlade prodaju otprilike jednom mjesečno, uobičajeno s rokom dospijeća 52 tjedna. Blagajnički zapisi temeljni su vrijednosni papiri kojim središnje

[15] Aljinović, Z., Marasović, B.: *Matematički modeli u analizi razvoja hrvatskog financijskog tržišta*, Ekonomski fakultet u Splitu, 2012., str. 27
[16] Tomić-Plazibat, N., Aljinović, Z., Marasović, B.:*Matematički modeli u financijskom upravljanju*, Ekonomski fakultet u Splitu, 2006., str.41

banke provode politiku otvorenog tržišta regulirajući količinu novca u optjecaju, a kamatna stopa na blagajničke zapise orijentacijska je kamatna stopa pri ugovaranju drugih vrsta kredita ili pri emisiji vrijednosnih papira.[17]

Promatramo tržište na kojem se kupuju i izdaju bezrizične obveznice koje imaocu obveznice garantiraju određeni novčani iznos na točno utvrđeni datum. Označit ćemo sa cijenu obveznice u vremenu *t* koja dospijeva u vremenu *T*, $t \le T$. Pretpostavit ćemo jediničnu isplatu o dospijeću (nominalna cijena je jedna novčana jedinica), odnosno:

$$P(T,T) = 1.$$

Podrazumijevamo li kontinuirano ukamaćivanje vrijedit će:

$$P(t,T)e^{(T-t)R(t,T)} = 1,$$

a od tu imamo

$$R(t,T) = -\frac{\ln P(t,T)}{T-t},$$

gdje je $R(t,T)$ kamatna stopa, odnosno stopa prinosa do dospijeća obveznice. $R(t,T)$ određuje koliki će biti prinos od obveznice koju kupujemo u trenutku *t* po cijeni $P(t,T)$, a o dospijeću obveznice dobijemo nominalni iznos $P(T,T) = 1.$

Iz posljednje relacije jasno je da je kretanje cijena obveznica i njihovih stopa inverzno, što znači da ako cijene obveznica na burzama vrijednosnih papira rastu, onda im stope prinosa opadaju i obratno.

S porastom cijene $P(t,T)$, pri čemu je $P(t,T) \in (0,1]$, *ln* $P(t,T)$ je po apsolutnoj vrijednosti sve manji, pa konačno i $R(t,T)$ prima sve manje vrijednosti.

Za fiksni *t*, vrijednosti od $R(t,T)$ predstavljaju vremensku ili ročnu strukturu kamatnih stopa, čiji se grafički prikaz naziva krivulje prinosa.

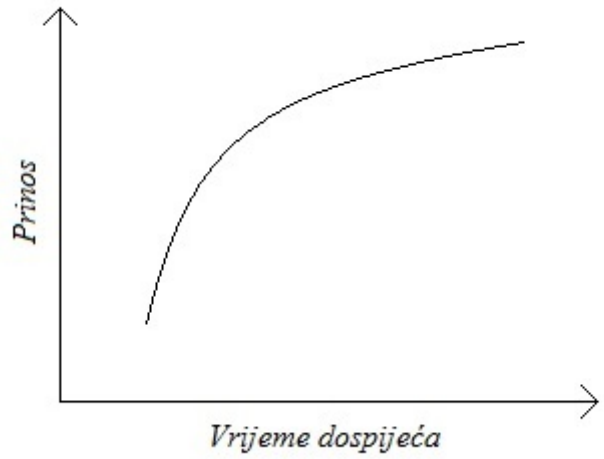
[17] Aljinović, Z., Marasović, B., Šego, B.: *Financijsko modeliranje*, II. Izmijenjeno i dopunjeno izdanje, Ekonomski fakultet Split, 2011., str.272.

2.2. Oblici krivulje prinosa

Oblik krivulje prinosa empirijski se pokazao kao značajan prediktor inflacije i realne ekonomske aktivnosti, međutim ne postoji standardna teorija zašto ta poveznica postoji.[18] Razlikuju se četiri moguća oblika krivulje prinosa: pravilni (rastući), inverzni (padajući), ravni te grbavi oblik.

Krivulja prinosa najčešće ima rastući oblik, što pokazuje da investitori traže veće prinose na dugoročna dospijeća, što znači da prinosi direktno ovise o vremenu dospijeća kao što se može vidjeti na sljedećoj slici:

Slika 1. Rastući oblik krivulje prinosa



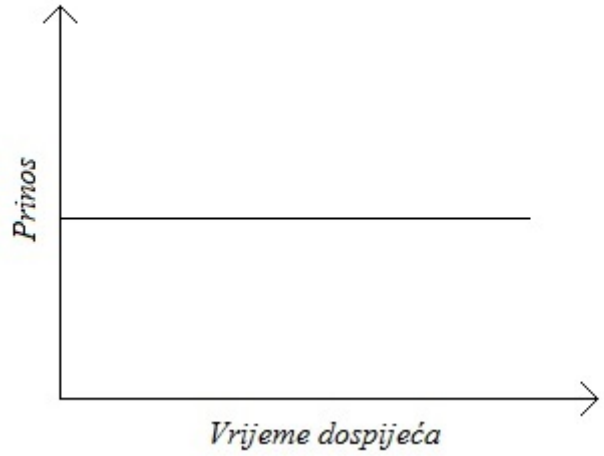
Izvor: Autor

Za ovakav oblik krivulje zaslužna je činjenica da investitori nisu sigurni za buduća kretanja kamatnih stopa i žele biti kompenzirani za povećanu nesigurnost ulaganjima na duži rok te se odriču od sadašnje potrošnje. Krivulja ima ovakav oblik kad su kamatne stope niske i kad je monetarna politika ekspanzivna. Kratkoročne obveznice imaju najniži povrat zato što je povezani rizik niži.[19] S povećanjem broja godina povećava se nesigurnost i rizik. Radi se o većem riziku jer se radi o višoj volatilnosti, riziku inflacije i riziku neplaćanja.[20] Ovakav oblik krivulje prinosa tipičan je za početak ekonomske ekspanzije ili kraja recesije.

[18] Estrella, A.: *Why Does the Yield Curve Predict Output and Inflation?*, Economic Journal, Vol. 115, No.505, pp. 722-744, 2005., 2. str.
[19] http://www.saperinvestire.it/index.php?option=com_content&task=view&id=275 (4.3.2014.)
[20] Aljinović, Z., Marasović, B.: *Matematički modeli u analizi razvoja hrvatskog financijskog tržišta*, Split: Ekonomski fakultet, 2012., str. 32.

Ravni oblik krivulje prinosa ukazuje da su prihodi jednaki neovisno o vremenu dospijeća. Za vrlo duge rokove dospijeća krivulje prihoda imaju tendenciju poravnanja.[21]
Ako ne postoji nesigurnost između sudionika tržišta i ako investitori znaju da će kratkoročne kamatne stope ostati konstantne u budućnosti, tada bi aktualne dugoročne kamatne stope trebale biti jednake onima kratkoročnima kako bi krivulja prinosa imala ravni oblik kao što se može primijetiti na sljedećoj slici:

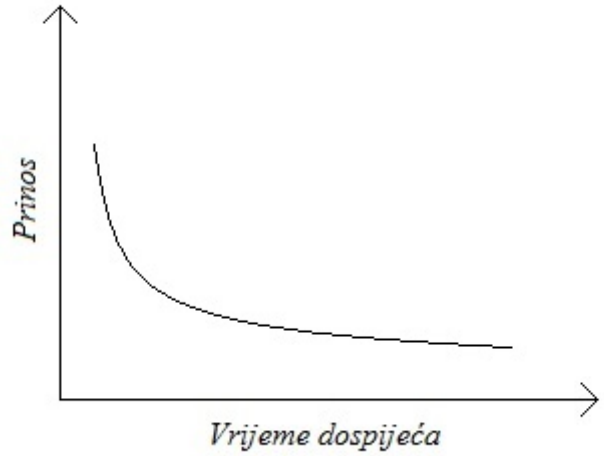
Slika 2. Ravni oblik krivulje prinosa



Izvor: Autor

Padajući oblik krivulje prinosa ukazuje da se prihodi umanjuju s povećanjem roka dospijeća kao što je vidljivo na sljedećoj slici:

Slika 3. Padajući oblik krivulje prinosa



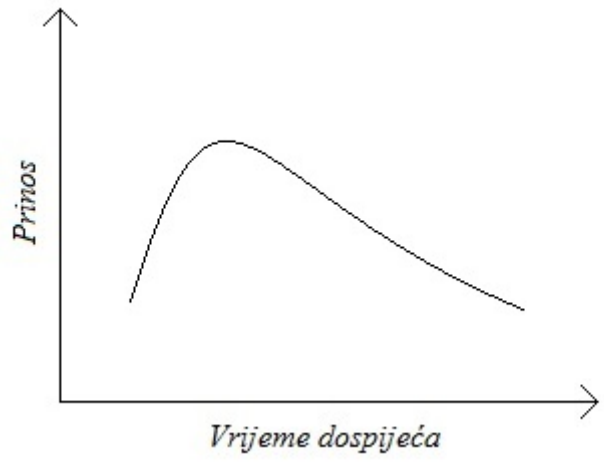
Izvor: Autor

[21] Ibidem

Kod ovog oblika krivulje dugoročni instrumenti donose niži prinos od kratkoročnih instrumenata. Ovo je najrjeđi oblik krivulje prinosa te se smatra prediktorom ekonomske recesije.[22] Padajući oblik krivulje znači da investitori jako malo vjeruju u ekonomiju te će radije kupiti dugoročne obveznice nego riskirati s kratkoročnim obveznicama.[23]
Inverzna krivulja prinosa uspješno je detektirala 6 od 7 usporavanja ekonomske aktivnosti od 1970. Možemo je koristiti kao vrijedan alat za predviđanje recesije 2 do 6 kvartala unaprijed. Negativna krivulja prinosa sugerira da tržište vjeruje da će stopa inflacije ostati niska. Prinos obveznica nadmašuju gubitak kapitala ostvaren zbog inflacije. Tehnički faktori, bijeg u sigurnost, globalne ekonomske ili valutne prilike mogu uzrokovati rast potražnje za obveznicama dužeg vremenskog okvira, uzrokujući pad dugoročnih prinosa. Negativni nagib krivulje, deflacija čini trenutne priljeve kapitala manje vrijednim od budućih priljeva.[24]

Grbavi oblik krivulje prinosa odraz je situacije u kojoj kratkoročne kamatne stope na početku rastu dok na duži rok opadaju i poravnavaju se, odnosno ispravljaju se.
Ako investitori očekuju da su kamatne stope konstante u kratkom roku i da će poslije snažno pasti krivulja prinosa imat će grbavi oblik, s rastom u kratkom roku i vrhom na datum kada se očekuje da će doći do pada kamatnih stopa te poslije vrha padajućim oblikom kao što se može vidjeti na sljedećoj slici:

Slika 4. Grbavi oblik krivulje prinosa (s lokalnim maksimumom, izbočinom)

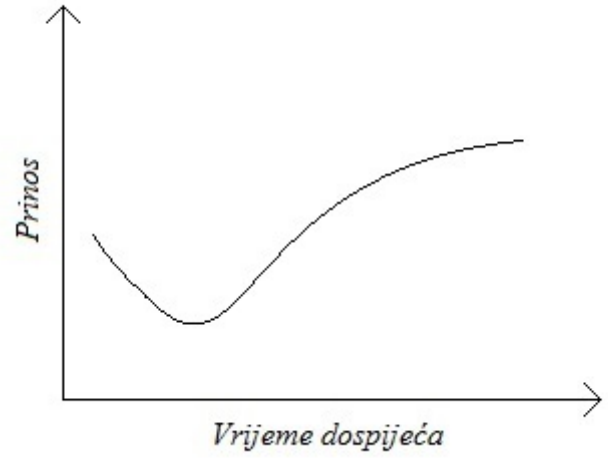


Izvor: Autor

[22] http://www.investopedia.com/terms/i/invertedyieldcurve.asp#axzz1yBOhN1n7 (4.3.2014.)
[23] http://useconomy.about.com/od/glossary/g/Inverted_yield.htm (4.3.2014.)
[24] http://themarketcycle.blogspot.com/2010/01/krivulja-prinos-yield-curve.html (9.3.2014.)

Krivulje ovog oblika česta su pojava predrecesijskog razdoblja i restriktivne politike zato što kamatne stope imaju tendenciju oštrog pada tijekom recesije.[25]
Grbavim oblikom se smatra i sljedeći oblik krivulje prinosa[26]:

Slika 5. Grbavi oblik krivulje prinosa (s lokalnim minimumom, udubinom)



Izvor: Autor

Ovakav grbavi oblik krivulje prinosa odraz je situacije u kojoj kratkoročne kamatne stope na početku padaju dok na duži rok rastu i poravnavaju se, odnosno ispravljaju se.
Ako investitori očekuju da su kamatne stope konstante u kratkom roku i da će poslije rasti krivulja prinosa imat će grbavi oblik, s padom u kratkom roku i dnom na datum kada se očekuje da će doći do rasta kamatnih stopa te poslije dna rastućim oblikom.

Krivulje prinosa mogu poprimiti i druge kompliciranе oblike. U principu, oblik postojećih krivulja prinosa u bilo kojem trenutku pruža informacije sudionicima financijskog tržišta, dobar vizualni prikaz povrata dostupnih ulaganjima na kratki i na dugi rok zahvaljujući kojemu investitori mogu odlučiti na koji rok ulagati.

[25] Aljinović, Z., Marasović, B.: *Matematički modeli u analizi razvoja hrvatskog financijskog tržišta*, Split: Ekonomski fakultet, 2012., str. 34.
[26] http://www.asset-analysis.com/bonds/bonycurve.html (4.3.2014.)

2. 3. Implicitna buduća kamatna stopa (FORWARD)

Implicitna buduća kamatna stopa (implicit forward interest rate) predstavlja vrijednost buduće kratkoročne kamatne stope koja osigurava jednaki prinos bilo da je riječ o ulaganju u niz kratkoročnih vrijednosnih papira ili o ulaganju u dugoročne vrijednosne papire za isto razdoblje.[27]

Zbog jednostavnosti govorit ćemo o implicitnoj kamatnoj stopi za obveznice s rokom dospijeća jedne godine, a naravno moguće je definirati i implicitnu kamatnu stopu za obveznice s rokom dospijeća dvije, tri ili više godina.

f_{t-1} je implicitna kamatna stopa obveznice s vremenom dospijeća od jedne godine, *t-1* godina od danas. Označimo li s i_t stopu prinosa, to jest kamatnu stopu obveznice s vremenom dospijeća *t* (godina), možemo pisati

$$(1+i_t)^t = (1+i_{t-1})^{t-1}(1+f_{t-1}), t \geq 1. \qquad (2.3.1)$$

Ovdje se lako dobije izraz za implicitnu kamatnu stopu:

$$f_{t-1} = \frac{(1+i_t)^t}{(1+i_{t-1})^{t-1}} - 1.$$

Ako u jednadžbi (2.3.1) umjesto $(1+i_{t-1})^{t-1}$ pišemo $(1+i_{t-2})^{t-2}(1+f_{t-2})$ i nastavimo tako dalje redom za $(1+i_{t-2})^{t-2}$, $(1+i_{t-3})^{t-3}$,..., dobit ćemo sljedeću jednadžbu:

$$(1+i_t)^t = (1+f_0)(1+f_1)\cdot\ldots\cdot(1+f_{t-1}) \qquad (2.3.2)$$

gdje je f_0 implicitna kamatna stopa nula godina od sada, to jest tekuća kamatna stopa obveznice s vremenom dospijeća jedna godina i_1. Dakle, ukupni prinos obveznice s vremenom dospijeća *t* možemo izraziti preko svih vrijednosti implicitne kamatne stope do vremena dospijeća.

Pokazuje se dovoljno dobrom aproksimacija vrijednosti od i_t, aritmetičkom sredinom od $f_0, f_1,..., f_{t-1}$ pa stoga vrlo često nalazimo na sljedeći izraz:

$$i_t \approx \frac{f_0 + f_1 + \ldots + f_{t-1}}{t}. \qquad (2.3.3)$$

[27] Aljinović, Z., Marasović, B., Šego, B.: *Financijsko modeliranje*, II. Izmijenjeno i dopunjeno izdanje, Ekonomski fakultet Split, 2011., str.273.

Rastuća krivulja prinosa, kada dakle s porastom vremena dospijeća rastu i kamatne stope, znači zapravo da i implicitne kamatne stope rastu tijekom vremena. Padajuća krivulja prinosa znači da se implicitne kamatne stope smanjuju tijekom vremena.[28]

Stopa prinosa i_t, dakle, računa se formulom (2.3.2). No naveli smo da je s formulom (2.3.3) dana dobra aproksimacija te stope. Postavlja se pitanje uz koje uvjete je to doista zadovoljavajuća aproksimacija. Odgovor slijedi direktno iz dokaza. Naime, kako je razvoj u red potencija logaritamske funkcije

$$\ln(1+x) = x - \frac{x^2}{2} + \frac{x^3}{3} - \ldots + (-1)^{n+1}\frac{x^n}{n} \pm \ldots, -1 < x < 1,$$

to jest

$$\ln(1+x) \approx x, -1 < x < 1,$$

ako jednakost (2.3.2) logaritmiramo

$$t\ln(1+i_t) = \ln(1+f_0) + \ln(1+f_1) + \ldots + \ln(1+f_{t-1})$$

i zatim primijenimo navedeni razvoj za logaritme nalazimo da je

$$ti_t \approx f_0 + f_1 + \ldots + f_{t-1},$$

odakle direktno, nakon dijeljenja s *t,* nalazimo aproksimaciju (2.3.3). Iz izvoda vidimo da je riječ o sve boljoj aproksimaciji što su vrijednosti stopa $f_0, f_1, \ldots, f_{t-1}$ bliže nuli.

2.4. Teorije vremenske strukture kamatnih stopa

Kretanje kamatnih stopa u zavisnosti o vremenu dospijeća, odnosno oblik krivulje stope prihoda imaju veliki učinak na financijska tržišta i na ponašanje financijskih posrednika. Posrednici će, nastojeći maksimalizirati svoj profit, itekako voditi računa o razlici između kratkoročnih i dugoročnih kamatnih stopa. Zapravo bismo mogli reći da je cijeli niz aktivnosti na financijskim tržištima uvjetovan odnosom između kamatnih stopa i vremena dospijeća. Stoga ne čudi da je vremenska struktura kamatnih stopa predmet mnogobrojnih ekonomskih istraživanja već cijelo stoljeće. Ta su istraživanja dala nekoliko prihvaćenih, danas bismo mogli reći tradicionalnih teorija, kojima se s obzirom na različite čimbenike, nastojalo objasniti i predvidjeti vremensku strukturu kamatnih stopa.[29]

[28] Ibidem, str.276.
[29] Aljinović, Z.: *Difuzijski modeli u analizi hrvatskog tržišta državnih vrijednosnica,* doktorska disertacija, Split, 2002., str. 64

Istaknut ćemo tri najpoznatije: Teorija očekivanja, Teorija preferencije (preferiranja) likvidnosti i Teorija segmentacije tržišta.[30]

Osnovna pitanja koja se postavljaju su sljedeća:
- Zašto se i kako kamatne stope na obveznice s različitim rokovima dospijeća mijenjaju tokom vremena?
- Zašto su kratkoročne kamatne stope niske, a krivulje prinosa većinom rastuće i obrnuto?
- Zašto krivulje prinosa najčešće imaju rastući oblik?

Teorija očekivanja nudi odgovore na prva dva pitanja, ali ne i na treće; teorija segmentiranih tržišta daje odgovor na treće pitanje, ali ne i na prva dva; teorija preferiranja likvidnosti i teorija preferiranog područja su oslonjene na osnovne pretpostavke potonjih teorija te pružaju cjelovite odgovore na sva tri pitanja.[31]

2. 4. 1. Teorija očekivanja

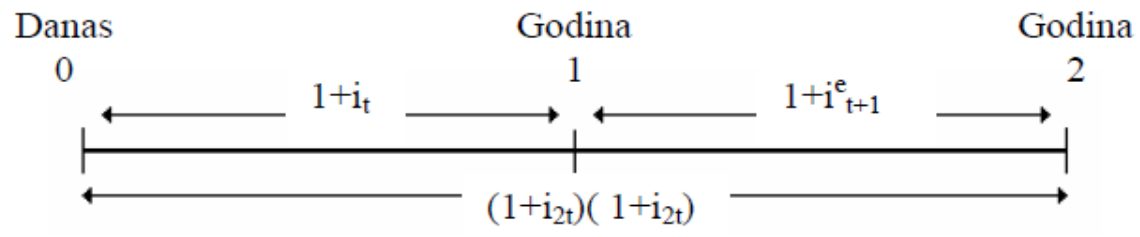
(Nepristrana) teorija očekivanja ((unbiased) expectations theory) najstarija je teorija koja analizira vremensku strukturu kamatnih stopa, a prve doprinose ovoj temi nalazimo čak u publikacijama s kraja 19., odnosno početka 20. stoljeća, među kojima su najvažnije: Fisher, I:Appreciation and Interest, Publications of the American Economic Association, 1896.; zatim Hicks, J.: Value and Capital, Oxford University Press, London, 1939. te Lutz, F.: The Structure of Interest Rates, Quarterly Journal of Economics, 1940. Teorija očekivanja vremenske strukture kamatnih stopa polazi od tvrdnje da će kamatna stopa na dugoročnu obveznicu izjednačiti prosječnu kamatnu stopu za koju investitori očekuju da će prevladati tijekom životnog vijeka obveznice.
Na primjer[32]: ukoliko se očekuje da će kratkoročna kamatna stopa na obveznice u toku sljedećih pet godina iznositi u prosjeku 8%, hipoteza očekivanja predviđa da će i kamatna stopa na petogodišnju obveznicu iznositi 8%. Ukoliko se nakon toga očekuje porast kratkoročne kamatne stope na 10% za sljedećih dvadeset godina, onda će kamatna stopa na 20-godišnju obveznicu iznositi 10 % i bit će veća od kamatne stope na petogodišnju obveznicu. Dakle, razlika kamatnih stopa na obveznice s različitim rokovima dospijeća,

[30]Prema http://web.efzg.hr/dok/EPO/sorsag/K03-Financijska%20okoloina.pdf (5.3.2014.)
[31] http://www.bbs.edu.rs/prof_predmet/jovo_jednak/FinTrzista/Poglavlje-6.pdf
[32] Prema http://www.vps.ns.ac.rs/arhiva/Komnenic/ponasanje_kamatnih_stopa_skripta.pdf (7.3.2014.)

pomoću teorije očekivanja, temelji se na očekivanju različitih vrijednosti očekivanih kratkoročnih kamatnih stopa za različite datume u budućnosti.
Osnova pretpostavka ove teorije je da kupci obveznica neće mijenjati preferencije između obveznica s različitim rokovima dospijeća. Tako kupci neće željeti posjedovati određenu količinu obveznica čiji je očekivani prinos manji od prinosa drugih obveznica različitog roka dospijeća. Obveznice koje se nalaze u takvom odnosu su savršeni supstituti, što u praksi znači da se očekivani prinosi na obveznice savršenih supstituta moraju izjednačiti.

Primjer[33]:
Investitori biraju između dvije strategije ulaganja:
- kupovine jednogodišnje obveznice i kupovina još jedne jednogodišnje obveznice nakon dospijeća prve obveznice i
- kupovine dvogodišnje obveznice, uz njeno zadržavanje do isteka roka dospijeća.
Ukoliko investitori posjeduju i jednogodišnje i dvogodišnje obveznice, obje strategije moraju osigurati isti očekivani povrat. Tako kamatna stopa na dvogodišnju obveznicu mora biti jednaka prosjeku kamatnih stopa na jednogodišnje obveznice. Trenutna kamatna stopa na jednogodišnju obveznicu iznosi 5% dok očekivana kamatna stopa na jednogodišnju obveznicu za sljedeću godinu iznosi 7%. Koliko je očekivani povrat kroz dvije godine? Kolika je kamatna stopa na dvogodišnju obveznicu kao ekvivalent dvije jednogodišnje kamatne stope?
Očekivani povrati kroz dvije godine u prosjeku iznosi: (5%+7%)/2 = 6%.
Tako će investitor biti spreman držati dvogodišnje obveznice samo ukoliko njihov očekivan prinos bude jednak 6%. Dakle da bi dvogodišnja obveznica bila poželjna za investitora, njena kamatna stopa mora biti jednaka prosječnoj kamatnoj stopi na dvije jednogodišnje obveznice koja u ovom primjeru iznosi 6%.

Slika 6. Prikaz jednogodišnje i dvogodišnje obveznice



Izvor: http://www.vps.ns.ac.rs/arhiva/Komnenic/ponasanje_kamatnih_stopa_skripta.pdf

[33] Ibidem

Ova se tvrdnja može poopćiti. Ukoliko razmatramo izbor da držimo jednu obveznicu kroz dva perioda i dvije obveznice kroz jedan period:

i_t = današnja (period *t*) kamatna stopa na obveznicu jednog perioda,

i^e_{t+1} = kamatna stopa na obveznicu jednog perioda, koju očekujemo u sljedećem periodu (*t+1*),

i_{2t} = današnja (period t) kamatna stopa na obveznicu koja dospijeva za dva perioda.

Očekivani prinos kroz dva perioda na ulaganje od 1 novčane jedinice u obveznicu koju ćemo držati dva perioda:

$$(1+i_{2t})(1+i_{2t})-1=1+2i_{2t}+(i_{2t})^2-1=2i_{2t}+(i_{2t})^2\approx 2i_{2t}$$

jer je $(i_{2t})^2 \approx 0$.

Ova relacija je izvedena na osnovi saznanja da ulaganje od 1 novčane jedinice vrijedi $(1+i_{2t})(1+i_{2t})$ na kraju drugog perioda. Oduzimanjem početnog ulaganja od 1 novčane jedinice i dijeljenjem s početnim ulaganjem dobiva se stopa povrata iz prethodne jednadžbe.

U slučaju druge strategije prema kojoj kupujemo obveznice jednog perioda, očekivani povrat na ulaganje od 1 novčane jedinice kroz dva perioda je:

$$(1+i_t)(1+i^e_{t+1})-1=1+i_t+i^e_{t+1}+i_t(i^e_{t+1})-1=i_t+i^e_{t+1}+i_t(i^e_{t+1})\approx i_t+i^e_{t+1}$$

jer je $$i_t(i^e_{t+1})\approx 0\,.$$

Prema teoriji očekivanja trebamo ove dvije relacije izjednačiti:

$$2i_{2t}=i_t+i^e_{t+1}$$

$$i_{2t}=\frac{i_t+i^e_{t+1}}{2}$$

Posljednja nam jednadžba govori da kamatna stopa za dva perioda mora biti jednaka prosjeku dvije kamatne stope za jedan period.

Iste ove korake možemo primijeniti na obveznice s dužim rokom dospijeća pa je kamatna stopa i_{nt} na obveznicu koja dospijeva za *n* perioda jednaka:

$$i_{nt}=\frac{i_t+i^e_{t+1}+i^e_{t+2}+\ldots+i^e_{t+(n-1)}}{n},$$

gdje je *n* broj godina.

Teorija očekivanja pruža sofisticirano objašnjenje vremenske strukture kamatnih stopa u raznim trenucima. Kada krivulja prinosa ima pozitivan nagib teorija očekivanja sugerira očekivanje rasta kratkoročnih kamatnih stopa u budućnosti. Kada se dugoročne kamatne stope nalaze iznad kratkoročnih dolazi do rasta prosjeka budućih kratkoročnih kamatnih stopa iznad

trenutnog nivoa tih stopa. Kada krivulja prinosa ima negativan nagib očekuje se da će prosjek budućih kratkoročnih kamatnih stopa biti ispod njihovog trenutnog nivoa, što znači da se u prosjeku očekuje njihov pad u budućnosti. Kada je krivulja prinosa ravnog oblika ova teorija sugerira da se kratkoročne kamatne stope u budućnosti neće mijenjati. Tako ova teorija objašnjava činjenicu da se kamatne stope na obveznice s različitim rokovima dospijeća kreću usporedno u vremenu. Teorija očekivanja također objašnjava i drugu činjenicu da krivulje prinosa imaju pozitivan nagib kad su kratkoročne kamatne stope niske i negativan nagib kad su visoke.[34]

Prema teoriji očekivanja oblik krivulje prinosa u određenom trenutku odražava očekivanja o kretanju kamatnih stopa u budućnosti pod pretpostavkom, da svi ulagači teže maksimalizaciji prinosa, da su indiferentni u odnosu na rizik, da imaju ista očekivanja i da su svi vrijednosni papir na tržištu u potpunosti zamjenjivi. Bez obzira na neodrživost ovih pretpostavki, višekratna testiranja potvrdila su da na oblik krivulje prinosa utječu očekivani prinosi ulagača.[35]

Nije upitno da elemente očekivanja treba uvažiti u analizi vremenske strukture kamatnih stopa, ali to nipošto ne može biti jedini čimbenik koji će utjecati na formiranje krivulje stope prihoda.[36]

2.4.2. Teorija segmentacije tržišta

Teorija segmentacije tržišta promatra tržišta obveznica različitih rokova dospijeća kao potpuno zasebna i segmentirana. Za svaku obveznicu različitog roka dospijeća, kamatna stopa je određena ponudom i potražnjom za tom obveznicom, što ne utječe na očekivane povrate obveznice s drugim rokovima dospijeća.
Ključna pretpostavka ove teorije je da obveznice s različitim rokovim dospijeća nisu supstituti te tako očekivani povrat obveznice s jednim rokom dospijeća nema utjecaja na potražnju za obveznicom s drugim rokom dospijeća. Ova teorija je u potpunosti suprotstavljena teoriji očekivanja koja pretpostavlja da su obveznice različitih rokova dospijeća savršeni supstituti.

[34] Ibidem
[35] http://www.moj-bankar.hr/Kazalo/T/Teorija-očekivanja (7.3.2014.)
[36] Tomić-Plazibat, N., Aljinović, Z., Marasović, B.: *Matematički modeli u financijskom upravljanju*, Split: Ekonomski fakultet, 2006., str. 44

Temelje ove teorije nalazimo u radu The Term Structure of Interest Rates, Quarterly Journal of Economics, 1957., autora J. M. Culbertsona.[37]

Teorija segmentacije[38] objašnjavajući zašto obveznice nisu supstituti polazi od ideje da investitori preferiraju upravo obveznice s određenim rokovima dospijeća koji točno odgovaraju njihovim potrebama i razlozima ulaganja novca. Stoga investitori samo promatraju očekivane povrate obveznica s rokovima dospijeća za koje su zainteresirani. Investitori se unaprijed odlučuju za obveznicu s određenim rokom dospijeća. Ukoliko uspiju uskladiti ročnost obveznice i svoje željeno razdoblje njenog držanja mogu osigurati siguran povrat bez rizika jer obveznicu neće željeti prodati prije isteka njenog dospijeća niti da je nakon njega reinvestiraju.

Prema teoriji segmentacije tržišta različite krivulje prinosa se objašnjavaju razlikama u ponudi i potražnji za obveznicama različitih rokova dospijeća. Ukoliko investitori generalno preferiraju kratkoročne obveznice jer nose manji kamatni rizik teorija segmentacije tržišta može objasniti činjenicu da su po pravilu krivulje prinosa pozitivnog nagiba. Dugoročne obveznice će imati niže cijene i veće kamatne stope jer je potražnja za njima manja od potražnje za kratkoročnim obveznicama. Iz tog razloga krivulja prinosa ima pozitivan nagib. Dakle, teorija segmentacije tržišta ističe daje tržište obveznica podijeljeno na kratkoročni, srednjoročni i dugoročni segment i da svakim od njih vlada određeni institucionalni investitor. Pri tome svaka grupa institucionalnih investitora specijalizira se za određenu vrstu obveznica. Tako, na primjer, komercijalne banke daju prednost likvidnosti i ulažu u kratkoročne vrijednosne papire, dok osiguravajuća društva zbog stabilnosti izvora financiranja mogu ulagati u dugoročne vrijednosne papire i tako, u pravilu, ostvarivati veću stopu prinosa. Teorijom segmentacije tržišta oblik krivulje prinosa se može objasniti na način da je nivo kamatnih stopa za kratkoročne i dugoročne vrijednosne papire određen neovisno na osnovi ponude i potražnje na svakom pojedinačnom tržištu. Do promjena u obliku krivulje prinosa dolazi zbog promjena u donosima ponude i potražnje u segmentima financijskog tržišta jer je otežano kretanje novca i kapitala među tržišnim segmentima.[39]

[37] Aljinović, Z., Marasović, B., Šego, B.: *Financijsko modeliranje*, II. Izmijenjeno i dopunjeno izdanje, Ekonomski fakultet Split, 2011., str.281

[38] http://www.vps.ns.ac.rs/arhiva/Komnenic/ponasanje_kamatnih_stopa_skripta.pdf (7.3.2014.)

[39] http://www.moj-bankar.hr/Kazalo/T/Teorija-segmentacije-tržišta (7.3.2014.)

2. 4. 3. Teorija preferiranja likvidnosti

Teorija preferiranja (preferencije) likvidnosti polazi od toga da će kamatna stopa na dugoročnu obveznicu izjednačiti prosjek kratkoročnih kamatnih stopa očekivanih s tijekom životnog vijeka obveznice uvećano za premiju likvidnosti koja zavisi od ponude i potražnje za tom obveznicom. Začetke ove teorije nalazimo već 1946. kada J. Hicks, u drugom izdanju knjige Value and Capital, ističe da se čistu teoriju očekivanja mora modificirati uvažavanjem principa premije likvidnosti.[40]

Glavna pretpostavka[41] ove teorije je da su obveznice različitih rokova dospijeća supstituti, ali ne i savršeni supstituti što pretpostavlja teorija očekivanja. Ova teorija međutim dopušta i mogućnost preferiranja određenih rokova dospijeća.

Investitori preferiraju kratkoročne obveznice jer nose manji kamatni rizik. Iz tog razloga investitorima treba ponuditi pozitivnu premiju likvidnosti kako bi ih se potaknulo na kupnju dugoročnih obveznica. Upravo ta činjenica, dodavanje premije likvidnosti, razlikuje ovu teoriju od teorije očekivanja.

Glavni zaključak teorije preferiranja likvidnosti može se zapisati pomoću relacije:

$$i_{nt} = \frac{i_t + i^e_{t+1} + i^e_{t+2} + \ldots + i^e_{t+(n-1)}}{n} + \ell_{nt}$$

gdje je ℓ_{nt} premija likvidnosti za obveznicu s rokom dospijeća od *n* razdoblja u razdoblju *t*, te je ona uvijek pozitivna i povećava se usporedno s ročnošću obveznice *n*.

Teorija preferiranja likvidnosti objašnjava činjenicu prema kojoj se obveznice različitih rokova dospijeća kreću usporedno u vremenu jer porast kratkoročnih kamatnih stopa ukazuje na mogućnost da će kratkoročne kamatne stope u budućnosti biti veće. Prvi član u gornjoj jednadžbi znači da će se dugoročne kamatne stope kretati usporedno s kratkoročnim.

Ova teorija objašnjava i zašto krivulja prinosa ima posebno strm pozitivan nagib kada su kratkoročne kamatne stope niske i negativan nagib kada su visoke. S obzirom da investitori generalno očekuju porast kamatnih stopa do normalnog nivoa, kada su kamatne stope niske prosjek budućih kamatnih stopa bit će veći od trenutnog nivoa. Dugoročne kamatne stope uz dodatak premije likvidnosti naći će se na daleko većem nivou u odnosu na kratkoročne kamatne stope pa će krivulja prinosa imati strm pozitivan nagib. Suprotno ovoj situaciji, u slučaju da su kratkoročne kamatne stope visoke ljudi će očekivati njihov povratak na niži nivo

[40] Aljinović, Z., Marasović, B., Šego, B.: *Financijsko modeliranje*, II. Izmijenjeno i dopunjeno izdanje, Ekonomski fakultet Split, 2011., str.280

[41] http://www.vps.ns.ac.rs/arhiva/Komnenic/ponasanje_kamatnih_stopa_skripta.pdf (7.3.2014.)

pa će u tom slučaju dugoročne kamatne stope pasti ispod nivoa kratkoročnih kamatnih stopa jer će prosječne očekivane kamatne stope pasti ispod nivoa trenutnih kratkoročnih stopa tako da niti pozitivna premija likvidnosti neće moći spriječiti naginjanje krivulje prema dolje. Teorija preferiranja likvidnosti[42] također objašnjava činjenicu da je krivulja prinosa uobičajeno pozitivnog nagiba. Ova teorija prepoznaje da premija raste s dospijećem obveznice čemu su glavni uzrok preferencije investitora za kratkoročnim obveznicama. Čak i ukoliko ne očekujemo promjenu kratkoročne kamatne stope u budućnosti dugoročne kamatne stope će biti veće od kratkoročnih,a krivulja prinosa će po pravilu biti pozitivnog nagiba.[43]

Doprinos teorije preferiranja likvidnosti je u tom što u objašnjenju krivulje prinosa uzima u obzir činjenicu da ulagači prilikom kupnje obveznica uvažavaju kako stopu prinosa tako i rizik. Do padajućeg oblika krivulje prinosa došlo bi samo iznimno, u slučaju kada bi očekivanja padajućih prinosa nadmašila premiju likvidnosti.[44]

Začeci teorije preferiranja likvidnosti se nalaze u teoriji koja, uz očekivanje budućih kratkoročnih kamatnih stopa, u analizi vremenske strukture uzima u obzir i pretpostavku da ulagači i izdavatelji vode računa i o vremenu dospijeća, tj. da iz razloga izbjegavanja rizika preferiraju jedno vrijeme dospijeća nad drugim, poznatoj kao teorija preferiranog područja.[45] Utemeljitelji ove teorije su F. Modigliani i R. Sutch, koji su istu iznijeli u radu „Innovations in Interest Rate Policy“, American Economic Review, 1966. Prema ovoj teoriji kamatna stopa za neko vrijeme dospijeća *t* nije više samo aritmetička sredina očekivanih kratkoročnih kamatnih stopa. U formiranju ove kamatne stope važnu ulogu ima vremenska premija, koja treba odraziti preferencije ulagača i izdavatelja spram vremena dospijeća, tj. stopa prinosa i_{nt} je korigirana za odgovarajuću vremensku premiju (term premium) tp_{nt} za vrijeme dospijeća *t*:

$$i_{nt} = \frac{i_t + i_{t+1}^e + i_{t+2}^e + ... + i_{t+(n-1)}^e}{n} + tp_{nt}.$$

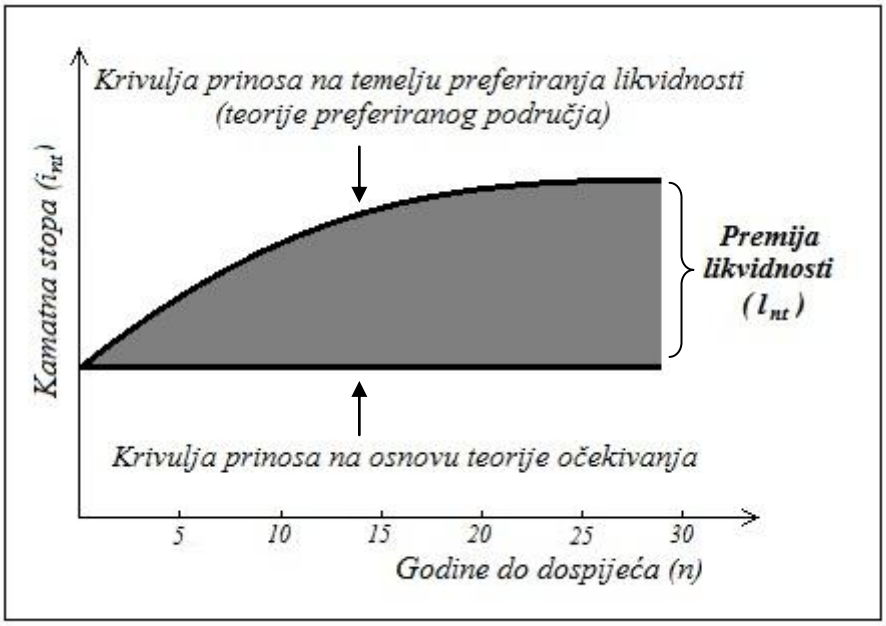
Vremenska premija može biti pozitivna ili negativna. Njena vrijednost održava relativnu sklonost ulagača i izdavača prema pdređenom dospijeću u odnosu na druga. Jednostavnije rečeno, njena vrijednost treba odraziti utjecaj preferiranja određenog vremena dospijeća u investicijskom odlučivanju.

[42] Ibidem
[43] Ibidem
[44] http://www.moj-bankar.hr/Kazalo/T/Teorija-preferencije-likvidnosti (7.3.2014.)
[45] Aljinović, Z., Marasović, B., Šego, B.: *Financijsko modeliranje*, II. Izmijenjeno i dopunjeno izdanje, Ekonomski fakultet Split, 2011., str.280

Što se samog očekivanja tiče, u formiranju stope prihoda ono igra istu ulogu kao i kod teorije očekivanja: očekivani rast kratkoročnih kamatnih stopa doprinosit će rastu krivulje stope prihoda, dok će očekivani pad kratkoročnih kamatnih stopa doprinijeti njenom izravnavanju odnosno padu.[46]

S obzirom na to da je premija likvidnosti uvijek pozitivan broj i da raste kako se povećava rok dospijeća, krivulja prinosa do koje se dolazi na temelju teorije preferencije likvidnosti i teorije preferiranog područja uvijek je iznad krivulje prinosa do koje se dolazi na temelju teorije očekivanja (krivulja prikazana na osnovu nepromijenjenih budućih jednogodišnjih kamatnih stopa) i ima oštriji nagib, što možemo vidjeti na slici 7.[47]

Slika 7. Odnos između teorije preferiranja likvidnosti (preferiranog područja) i teorije očekivanja



Izvor: Autor

Teorija preferiranja likvidnosti i teorija preferiranog područja objašnjavaju sljedeće:

(1) kamatne stope na obveznice različitih rokova dospijeća imaju tendenciju ujednačenog kretanja tokom vremena;

(2) krivulje prinosa imaju obično rastući oblik;

(3) kada su kratkoročne kamatne stope niske, krivulja prinosa će uglavnom imati oštriji uzlazni nagib, a kada su one visoke, krivulje prinosa će uglavnom biti obrnute.

[46] Ibidem

[47] Prema http://www.bbs.edu.rs/prof_predmet/jovo_jednak/FinTrzista/Poglavlje-6.pdf (12.3.2014.)

Uspoređujući izložene tri teorije krivulje prinosa odnosno vremenske strukture kamatnih stopa treba reći da se one međusobno ne isključuju već se nadopunjuju. Na taj način one omogućavaju pored ostalih čimbenika bolju interpretaciju oblika krivulje prinosa radi što učinkovitijeg ulaganja u određene vrste vrijednosnih papira.[48]

2. 5. Uloga krivulje prinosa

2. 5. 1. Mikroekonomski aspekt

Krivulja prinosa pruža referentni alat za usporedbu prinosa i roka dospijeća obveznica koji može biti korišten u više svrha[49]:
- krivulja prinosa ima impresivan utjecaj kao vodeći indikator ekonomskih uvjeta, upozoravajući investitore na prijeteću recesiju ili pak nadolazeću uzlaznu putanju gospodarstva,
- krivulja prinosa se može koristiti kao mjerilo određivanja cijena drugih vrijednosnih papira s fiksnom kamatnom stopom. Primjerice, američke trezorske obveznice nemaju percipirani kreditni rizik pa bi većina vrijednosnih papira s fiksnom kamatnom stopom, koji povlače za sobom kreditni rizik, trebali nositi viši prinos nego trezorske obveznice.

Na primjer, visoko kvalitetna korporativna obveznica s rokom dospijeća od tri godine bi mogla postići prinos od 0,50 posto, ili 50 baznih poena, više nego trezorska obveznica s rokom dospijeća od tri godine.[50]

Važna uloga krivulje prinosa je i u identifikaciji precijenjenih ili podcijenjenih obveznica. Imajući na umu obrnuto proporcionalan odnos između cijene i prinosa obveznice, za ulagača to znači da treba izbjegavati obveznice koje se nalaze ispod krivulje prinosa jer im je cijena previsoka a stopa prinosa preniska, tj.precijenjene su.[51]

Predviđajući pomake u krivulje prinosa, menadžeri fiksnih kamatnih stopa mogu pokušati zaraditi iznadprosječne povrate na svoje portfelje obveznica. Nekoliko strategija krivulje

[48] http://www.moj-bankar.hr/Kazalo/T/Teorija-segmentacije-tržišta (7.3.2014.)
[49] Aljinović, Z., Marasović, B.: *Matematički modeli u analizi razvoja hrvatskog financijskog tržišta*, Split: Ekonomski fakultet, 2012., str. 34.
[50] http://www.rethinkyourdefence.com.au/yield_curve_basics.asp?expand=1 (9.3.2014.)
[51] Prohaska, Z.: Analiza vrijednosnih papira, Infoinvest, Zagreb, 1996., str.138

prinosa su razvijeni u pokušaju ostvarivanja nadprosječnih povrata u različitim okruženjima kamatnih stopa. Tri strategije krivulje prinosa[52] fokusiraju se na razmaku dospijeća obveznica u portfelju:

1. *Strategija metka*: Portfelj je strukturiran tako da su rokovi dospijeća vrijednosnica visoko koncentrirani u jednoj točki na krivulji prinosa. Na primjer, većina obveznica u portfelju može dospijevati za 10 godina.

2.*Uteg strategija*: Dospijeća vrijednosnih papira u portfelju su koncentrirana na dva ekstrema, kao što su pet godina i 20 godina.

3. *Strategija ljestvi:* U ovoj strategiji portfelj ima jednake količine vrijednosnica koje dospijevaju periodično obično svake godine.

U principu, strategija metka pobjeđuje kada krivulje prinosa poprima strmi oblik, dok uteg strategija koristi kada je krivulja ravna. Ulagači obično koriste pristup ljestvi kako bi smanjili rizik od reinvestiranja značajnog udjela njihovog novca[53] u tržište niskih kamatnih stopa. Vrlo dobro je poznata i strategija *kretanja po krivulji prinosa*: kako se obveznica približava roku dospijeća na uzlaznom dijelu krivulje prinosa onda se njena vrijednost određuje na razini nižeg prinosa i pri višoj cijeni. Korištenjem ove strategije, obveznica se drži za vrijeme koje je uračunato u cijenu i prodaje prije dospijeća kako bi se ostvario kapitalni dobitak zbog povećanja njene cijene, i reinvestiranja dobiti od prodaje u dugoročnije vrijednosnice koje nose više stope povrata. Ako ovakav potez uspije (na primjer, nagib krivulje se značajnije ne mijenja protiv banke), banka će ostvariti oboje, i viši trenutačni prihod i više buduće povrate na svoj portfelj.[54] Popularan naziv za ovakvo kretanje po krivulji prinosa je ,,jahanje na krivulji prinosa".

Na primjer, ako diler kupi obveznicu 6 mjeseci do dospijeća, zadrži ju 3 mjeseca, konvertira u gotovinu i kupi sljedeću šestomjesečnu obveznicu, može ostvariti dobit na dva načina – budući da je prinos niži na tromjesečnu nego na šestomjesečnu obveznicu diler će ostvariti dobit na toj prodaji, a s druge strane, kupovinom sljedeće šestomjesečne obveznice zamjenjuje obveznicu s nižim povratom obveznicom višeg povrata uz nižu cijenu.[55] Međutim,

[52] Mast Henderson, T.: *Fixed Income Stategy: A practitioner's Guide to Riding the Curve*, John Wiley and Sons, str.1.-222., 2003.
[53] Aljinović, Z., Marasović, B.: *Matematički modeli u analizi razvoja hrvatskog financijskog tržišta*, Split: Ekonomski fakultet, 2012., str. 35.
[54] Rose, S. Peter: *Menadžment komercijalnih banaka*, Mate, Zagreb, 2005., str. 339
[55] Prema http://www.mojfaks.com/skripte/efos/financijske-institucije-i-trzista (9.3.2014.)

mana je u tome što je jahanje krivulje prinosa riskantno jer one neprekidno mijenjaju svoj oblik.
Bitno je i istaknuti da rastuća krivulja prinosa je općenito povoljna za banke i štedionice jer one većinu sredstava pribavljaju kroz kratkoročne depozite, a daju zajmove kroz duži rok. Što oštrije krivulja raste prema gore širi je raspon između kamatnih stopa po kojima se uzimaju i daju zajmovi, te su veće mogućnosti za financijske posrednike.[56]

2. 5. 2. Makroekonomski aspekt

Vremenska struktura kamatnih stopa važna je za makroekonomsku analizu zato što utječe na potrošačke odluke i ulaganja ekonomskih agenata, a time i agregatne potražnje, koja je jedna od odrednice inflacije u gospodarstvu. S financijskog gledišta, postojanje krivulje prinosa pogoduje razvoju domaćih tržišta kapitala, primarnih i sekundarnih, omogućujući oporavak financijskih instrumenata (duga i derivata).[57]

Krivulja prinosa može biti iskorištena za izračun sigurne buduće kratkoročne kamatne stope na instrumente s fiksnim prihodom. Ta se kamata zove terminska kamatna stopa. Terminska stopa prenosi informaciju o inflatornim očekivanjima preko Fisherove jednadžbe, koja kaže da se nominalna kamatna stopa može dobiti jednostavnim zbrajanjem realne kamatne stope i stope inflacije $i_t = r_t + \pi_t$.[58]

Očekivanja nominalnih i realnih kamatnih stopa mogu se izračunati uklapanjem krivulje prinosa koristeći nominalne i realne kamatne stope i izračunavanjem odgovarajućih terminskih stopa. Kako bi se došlo do inflatornih očekivanja obično se usklađuju krivulje nominalnog i realnog prinosa, gdje je krivulja realnog prinosa podešena korištenjem podataka o indeksiranim obveznicama.
Nagib krivulje prinosa je empirijski značajan prediktor inflacije i realne ekonomske aktivnosti zbog sljedećih razloga. Trenutna monetarna politika ima značajan učinak na rast krivulje prinosa a time i na realnu aktivnost kroz nekoliko sljedećih kvartala. Porast u kratkom roku može izravnati krivulju prinosa, ali i usporiti realni rast u kratkom roku. Ova veza, međutim, je samo jedan dio objašnjenja za korisnost krivulje prinosa kao alata za predviđanje.

[56] Ibidem
[57] Aljinović, Z., Marasović, B.: *Matematički modeli u analizi razvoja hrvatskog financijskog tržišta*, Split: Ekonomski fakultet, 2012., str. 35.
[58] Jefferson Institute: *Tržište obveznica u Srbiji: Izazovi regulative za efikasno tržište*, Beograd, 2005. , str. 57.

Očekivanja buduće inflacije i realnih kamatnih stopa koje se nalaze unutar krivulje prinosa po cijeloj njenoj duljini također igraju važnu ulogu u predviđanju ekonomskih aktivnosti. Terminska stopa može biti rastavljena na očekivane realne kamatne stope i očekivanu stopu inflacije, od kojih svaka može biti korisna u predviđanju**.** Očekivana realna stopa može biti povezana s očekivanjima buduće monetarne politike i stoga budućeg realnog rasta. Nadalje, zbog toga što inflacija ima tendenciju pozitivne veze s aktivnosti, očekivana stopa inflacije može biti informativna o budućem rastu.

Većina država u neko vrijeme pokušava utjecati na kratkoročne kamatne stope kao polugu realne ekonomije ili u pokušaju utjecanja na stopu inflacije. To se obično ostvaruje kada se monetarna vlast angažira u operacijama na otvorenom tržištu (kupuje ili prodaje vrijednosnice) ili prijeti da će napraviti isto. Promjene u kratkoročnim kamatnim stopama (s nepromijenjenim inflatornim očekivanjima) mogu utjecati na zalihe i potrošnju, posebno trajnih dobara. Kratkoročne kamatne stope mogu imati utjecaj na razinu dugoročnih kamatnih stopa na državne i korporativne obveznice. Kamatne stope na korporativne obveznice mogu utjecati na investicije u tvornice i opremu. Dakle, monetarna politika države može utjecati na realnu ekonomsku aktivnost. Države su u mogućnosti ,,izokrenuti" krivulju prinosa. Podizanjem kratkoročne kamatne stope (kako bi se potakla štednja) i simultano snižavajući dugoročne kamatne stope potiču se investicije. Međutim, ako teorija očekivanja krivulje prinosa ,,drži vodu" onda autoriteti ne mogu izmijeniti odnos između kratkoročnih i dugoročnih kamatnih stopa i moraju prihvatiti posljedice slobodnog tržišta za dugoročne stope zbog bilo koje promjene koju kratkoročne kamatne stope mogu izgraditi.[59] Promjene u domaćim kratkoročnim stopama mogu utjecati na tokove kapitala, tečaj i time cjenovnu konkurentnost, volumen neto izvoza te razinu zaposlenosti i proizvodnje.

Drugi razlog zbog čega su države zainteresirane za determinante kretanja cijena obveznica je u tome što obveznice čine bitan dio portfelja većine financijskih institucija. Varijacije u cijenama obveznica utječu na bilance financijskih institucija. Središnje banke žele znati koliko je vjerojatno da će varijacije u cijenama obveznica izložiti riziku financijsku održivost takve institucije. Ako je tržište obveznica pretjerano volatilno, tada postoji dodatni razlog za intervenciju države u takva tržišta.[60]

[59] Aljinović, Z., Marasović, B.: *Matematički modeli u analizi razvoja hrvatskog financijskog tržišta*, Split: Ekonomski fakultet, 2012., str. 36.
[60] Ibidem

3. PARAMETRIJSKI MODELI ZA PROCJENU KRIVULJE PRINOSA

Parametrijski modeli za procjenu krivulje prinosa također su poznati i kao modeli uštede pošto se temelje na štedljivoj parametrizaciji izabranih pojmova funkcija strukture. Štedljivi modeli procjenjivanja pokušavaju procijeniti krivulje prinosa kao linearnu kombinaciju izabranih nesegmentiranih osnovnih funkcija, koje su definirane nad cijelim intervalom dospijeća. Parametri modela procijenjeni su na način kako bi se smanjio zbroj kvadrata reziduala između trenutno promatranih i teorijskih cijena obveznica ili prinosa do dospijeća. Parametrijske metode za procjenu krivulje prinosa razvili su Nelson i Siegel, a dalje ih je razvijao Svensson, Diebold te Li i drugi. Parametrijske metode se razlikuju prema vrsti procijenjene strukture funkcija, a poznate su funkcija popusta, nul-kupon krivulja prinosa ili forward krivulja, pri čemu se zadnja najčešće koristi.[61]

3.1. Nelson – Siegelov model[62]

Nelson-Siegelov model spada među najkorištenije modele za izračun krivulje prinosa. Nelson i Siegel[63] su predstavili jednostavan parametrijski model koji je dovoljno fleksibilan da podrži odgovarajući oblik krivulje prinosa: monotoni (rastući, padajući, ravni) ili grbavi (izbočeni ili u obliku slova S).

Skupina funkcija koje općenito generiraju tipičnu krivulju prinosa i njene oblike u uskoj su vezi s rješenjima diferencijalnih ili diferencijskih jednadžbi. Ako je trenutačna forward stopa s dospijećem T, $f(t,T)$, rješenje diferencijalne jednadžbe drugog reda s realnim i nejednakim korijenima, onda je dana u obliku:

$$f(t,T) = \beta_0 + \beta_1 \cdot e^{-\frac{T-t}{\tau_1}} + \beta_2 \cdot e^{-\frac{T-t}{\tau_2}}.$$

[61] Grum, A.: *The Effect of Parallel OTC-DVP Bond Market Introduction on Yield Curve Volatility*, Zb. Rad. Ekon. fak. Rij., vol. 24, 2006., str. 125

[62] Prema Aljinović, Z., Marasović, B.: *Matematički modeli u analizi razvoja hrvatskog financijskog tržišta,* Ekonomski fakultet u Splitu, 2012. , str.37-39

[63] Nelson, C. R., Siegel, A. F.: *Parsimonious modeling of yield curves*, Journal of Business,Vol. 60(1987.), str. 473-89

gdje τ_1 i τ_2 su vremenske konstante povezane s jednadžbom, dok su β_0, β_1 i β_2 parametri određeni početnim uvjetima.

Sada se nul-kupon kamatne stope *R(t)* mogu izračunati uprosječivanjem trenutačnih forward stopa:

$$R(t,T) = \frac{1}{T-t}\int_t^T f(x,T)dx. \tag{3.1.1}$$

Još jednostavniji model koji može generirati jednak raspon oblika je dan kroz trenutačnu forward stopu koja je rješenje diferencijalne jednadžbe drugog reda s jednakim korijenima:

$$f(t,T) = \beta_0 + \beta_1 \cdot e^{-\frac{T-t}{\tau}} + \beta_2 \frac{T-t}{\tau} e^{-\frac{T-t}{\tau}}. \tag{3.1.2}$$

Supstituiranjem (3.1.2) u (3.1.1) i integriranjem, dobije se:

$$R(t,T) = \frac{1}{T-t}\int_t^T f(x,T)dx = \frac{1}{T-t}\int_t^T \left(\beta_0 + \beta_1 \cdot e^{-\frac{T-x}{\tau}} + \beta_2 \frac{T-x}{\tau} e^{-\frac{T-x}{\tau}}\right)dx =$$

$$\frac{1}{T-t}\left(\beta_0(T-t) - \beta_1 \tau e^{-\frac{T-t}{\tau}} + \beta_1\tau + \beta_2\tau\left(-\frac{T-t}{\tau}e^{-\frac{T-t}{\tau}} - e^{-\frac{T-t}{\tau}} + 1\right)\right).$$

Nakon jednostavnijeg sređivanja dobije se izraz za kamatnu stopu:

$$R(t,T) = \beta_0 + (\beta_1 + \beta_2)\frac{1-e^{-\frac{T-t}{\tau}}}{\frac{T-t}{\tau}} - \beta_2 e^{-\frac{T-t}{\tau}} \tag{3.1.3}$$

Odakle je vidljivo da je vremenska struktura kamatnih stopa, odnosno krivulja prinosa u Nelson-Siegelovom modelu funkcija četiri parametara: $\beta_0, \beta_1, \beta_2$ i τ.

Lako se uočava da je:

$$\lim_{T\to\infty} R(t,T) = \beta_0 \tag{3.1.4}$$

tako da parametar β_0 odgovara dugoročnoj kamatnoj stopi.

Nadalje je:

$$\lim_{T \to t} R(t,T) = \beta_0 + \beta_1 \qquad (3.1.5)$$

što implicira kako je zbroj vrijednosti parametara β_0 i β_1 jednak kratkoročnoj kamatnoj stopi (very short term, spot interest rate), koja primjerice u stohastičkim modelima kamatnih stopa ima ulogu ključne varijable i aproksimira se različitim oblicima stohastičkih diferencijalnih jednadžbi.

Vidimo, prema rezultatima (3.1.4) i (3.1.5) da je β_1 ustvari razlika između kratkoročne i dugoročne stope. Tako predznak parametra β_1 određuje nagib krivulje prinosa. Ako je β_1 negativan, krivulja prinosa i forward krivulja će imati pozitivan nagib i obrnuto.

Parametar β_2 smatra se identifikatorom magnitude i mjera izbočine na krivulji prinosa. Ako je β_2 pozitivan,u vremenu τ će se pojaviti izbočina, a ako je negativan, umjesto izbočine pojavit će se oblik slova U (U-shape) ili udubina.

Parametar τ, koji je uvijek pozitivan, specificira položaj izbočine ili oblik slova U na krivulji. Ako je β_2 vrijednosti jednakoj ili približno jednakoj 0, krivulja prinosa bit će monotona, bez udubine ili izbočine, odnosno lokalnih ekstrema.

3.2. Svenssonov model

Svenssonov model sadrži drugu izbočinu/dolinu kroz dodatni faktor što omogućuje poprimanje više i kompliciranijih oblika krivulje prinosa.[64] Međutim kako bi se povećala fleksibilnost i poboljšalo prilagođavanje, Nelson-Siegelova funkcija (3.1.2) se proširuje četvrtim parametrom i drugim nagibom/udubljenjem. Ova dva dodatna parametra se označavaju s β_3 i τ_2. Nova funkcija dana je sljedećom relacijom[65]:

$$f(t,T) = \beta_0 + \beta_1 e^{-\frac{T-t}{\tau_1}} + \beta_2 \frac{T-t}{\tau_1} e^{-\frac{T-t}{\tau_1}} + \beta_3 \frac{T-t}{\tau_2} e^{-\frac{T-t}{\tau_2}}.$$

Analogno izvodu u Nelson-Siegelovom modelu, vremenska struktura kamatnih stopa dana je u sljedećem obliku:

[64] Annaert, J., Claes, A. G. P., Ceuster, M. J. K., Zhang, H.: *Estimating the Yield Curve Using Nelson-Siegel Model – A Ridge Regression Approach*, Universiteit Antwerpen, Belgium, 2010., p.1

[65] Prema Svensson, L.E.O.: *Estimating and interpreting foward interest rates: Sweden 1992-1994*, Cambridge: National Bureau of Economic Research (Working paper, 4871)

$$R(t,T) = \beta_0 + \beta_1 \frac{1-e^{-\frac{T-t}{\tau_1}}}{\frac{T-t}{\tau_1}} + \beta_2 \left(\frac{1-e^{-\frac{T-t}{\tau_1}}}{\frac{T-t}{\tau_1}} - e^{-\frac{T-t}{\tau_1}} \right) + \beta_3 \left(\frac{1-e^{-\frac{T-t}{\tau_2}}}{\frac{T-t}{\tau_2}} - e^{-\frac{T-t}{\tau_2}} \right).$$

Parametri β_0 i τ_1 moraju biti pozitivni, a isto tako i parametar τ_2 treba biti pozitivan te on određuje poziciju drugog nagiba ili udubljenja dok je parametar β_3 analogan parametru β_2 i određuje oblik i smjer drugog nagiba odnosno udubljenja.[66]

Nelson-Siegelov model, koji ima samo 4 parametra, omogućava procjenu krivulje prinosa, bez korištenja previše parametara, kada je broj promatranih cijena obveznica vrlo mali. Svenssonov modela koji ima dva dodatna parametra ima sposobnost prilagođavanja kompliciranijim oblicima krivulje, posebno kod „izbočine“ kad se radi o kratkom roku dospijeća i konkavnog oblika kod dugog dospijeća.[67]
U praksi Nelson-Siegelov model češće ima prednost pri korištenju, osobito kad se raspolaže s malo ulaznih podataka. Nelson i Siegel su pokazali da je njihov model sposoban zabilježiti mnoge od tipično primijećenih oblika koje krivulja prinosa poprimi tijekom vremena.[68]
Zbog dodatnog parametra Svenssonov model je kompliciraniji za izračun te ima ograničenu mogućnost prilagodbe nepravilnim oblicima krivulje prinosa.[69] Upravo iz tog razloga nekad procjena krivulje prinosa Nelson-Siegelovim modelom može biti točnija.

Zbog malog broja promatranih obveznica na hrvatskom financijskom tržištu, prednost se daje štedljivijem Nelson-Siegelovom modelu.

[66] http://e-lib.efst.hr/2012/2101815.pdf , str.31-32 (19.4.2014.)
[67] Aljinović, Z.; Poklepović, T.; Katalinić, K.: *Best Fit Model for Yield Curve Estimation,*Croatian Operational Research Review (CRORR), Vol. 3(2012.), pp. 32-33
[68] Berec, R.: *Extraction of Nelson-Siegel Factors from Bond Prices*, Comenius University in Bratislava - Faculty of Mathematics, Physics and Informatics- Department of Applied Mathematics and Statistics, 2010., str.8
[69] Marciniak, M.: *Yield Curve Estimation at the National Bank of Poland*, National Bank of Poland working paper N° 47, 2006., p.58

3.3. Diebold-Li faktorizacija

Pored drugih statističkih modela za kamatnu stopu, utjecajan model dizajnirali su Diebold i Li[70]. Ovaj model predstavlja dinamički nastavak Nelson-Siegelovog modela. Vremenska struktura kamatnih stopa, odnosno krivulja prinosa prikazana je u sljedećem obliku:

$$y_t(\tau) = \beta_{1t} + \beta_{2t}\left(\frac{1-e^{-\lambda_t\tau}}{\lambda_t\tau}\right) + \beta_3\left(\frac{1-e^{-\lambda_t\tau}}{\lambda_t\tau} - e^{-\lambda_t\tau}\right)$$

gdje $y_t(\tau)$ predstavlja stvarnu ili nominalnu kamatnu stopu, τ je rok dospijeća dane obveznice i *t* današnji datum. Ova faktorizacija lagano odstupa od Nelson-Siegelova modela i daje prostora intuitivnom tumačenju tri latentna dinamična faktora β_{1t}, β_{2t} i β_{3t}.[71] Pošto je opterećenje na prvom faktoru konstantno, može ga se interpretirati kao dugoročni faktor, koji ne konvergira ka nuli s povećanjem roka dospijeća. Opterećenje na drugom faktoru počinje s 1, ali brzo pada na nulu te se smatra kratkoročnim faktorom. Opterećenje na trećem faktoru s početkom u 0, rastom i onda polaganim padom, smatra se srednjoročnim faktorom.

Ekstenzija formulirana od strane Diebold i Li-ja, čini Nelson-Siegelov model dinamičkim (prilagođavajući nekoliko promatranih datuma za krivulju prinosa) pomoću postupaka u 3 faze[72]:

1. Parametri β_{1t}, β_{2t} i β_{3t} procjenjuju se metodom najmanjih kvadrata za svaki datum uz fiksiran λ_t (koji maksimizira faktor opterećenja srednjoročnog dijela).

2. Dinamičnost sustava je osigurana modelom vektorske autoregresije (VAR) za parametre β_{1t}, β_{2t} i β_{3t}, koji su procijenjeni u prvoj fazi.

3. Prognoze za ove parametre napravljene su kroz VAR model procijenjen za vektore β_{1t}, β_{2t} i β_{3t}. Zamjenom prognoziranih parametara u Nelson-Siegelovom modelu koji je zadan jednadžbom, moguće je prognozirati buduće krivulje kamatnih stopa.

[70] Diebold X. F., Li, C.:"*Forecasting the term structure of government bond yields*", Yournal of Econometrics 130, 2006., pp. 337-364
[71] Jefferson Institute : *Tržište obveznica u Srbiji*: *Izazovi regulative za efikasno tržište*, Beograd, 2005., str.43
[72] Prema http://www.ssc.upenn.edu/~fdiebold/papers/paper49/Diebold-Li.pdf

Prema Dieboldu i Li-ju, ova dinamička formulacija ima svrhu prepoznavati niz činjenica u strukturi kamatnih stopa:

- oblik krivulje se može promijeniti s vremenom iz konkavnog u konveksni oblik i obrnuto uz mogućnost nastajanja izbočina i udubina,
- dulji kraj krivulje prinosa je manje promjenjiv nego kraći kraj,
- kratkoročne stope su manje stalne od dugoročnih stopa.

Isto tako, Diebold-Lijev model jednostavan je za primjenu te ima vrhunske potencijale predviđanja u usporedbi sa vezanim modelima u literaturi, no neki problemi se i dalje javljaju kod korištenja.

Funkcionalna forma koja je prisvojena od Nelson-Siegelova modela ne dozvoljava praćenje kompliciranijih krivulja prinosa, kao što su one kada postoji više promjena u nagibu i zakrivljenosti.[73] Također teško je fiksirati λ_t (linearizacija primijenjena u modelu) kod nestabilnih krivulja prinosa, kao što su države u nastajanju.

[73] http://e-lib.efst.hr/2011/2090074.pdf, str.31

4. HRVATSKO FINANCIJSKO TRŽIŠTE DUŽNIČKIH VRIJEDNOSNIH PAPIRA

Javni je dug[74] je jedna od ključnih ekonomskih varijabli pri određivanju gospodarske politike. Njega čine novčani iznosi koje pozajmljuje država kako bi financirala prošle proračunske deficite.

Postoje tri osnovna institucionalna rješenja za upravljanje javnim dugom.[75]

Ministarstvo financija upravlja javnim dugom i odgovorno je za taktičke i strateške, ali i za mnoge druge funkcije (Slovenija, Italija). Pritom je središnja banka odgovorna samo za tehničke aspekte upravljanja dugom kao što je prodaja instrumenata duga i vođenje sustava plaćanja i namirenja.

Središnja banka ima najvažniju ulogu u formuliranju politike upravljanja dugom i odgovorna je za stratešku politiku i kratkoročno upravljanje javnim dugom (Danska). Time se osigurava određeni stupanj diskrecije središnje banke u upravljanju dugom, što je važno kada se žele uskladiti procesi upravljanja javnim dugom i vođenja monetarne politike. Mnoge funkcije upravljanja javnim dugom obavlja *poseban ured* ili *agencija za upravljanje dugom* (Švedska, Irska). Tim se rješenjem ostvaruje potpunije razdvajanje fiskalne i monetarne politike od politike upravljanja dugom. Takvi se uredi osnivaju tek posljednjih dvadesetak godina, s izuzetkom Švedske, koja takav ured ima od 1789. godine.

Država se može zadužiti kratkoročno ili srednjoročno-dugoročno. Pod kratkoročnim zaduživanjem podrazumijeva se zaduživanje putem trezorskih zapisa ili kroz nepodmirene obveze dok se pod srednjoročno-dugoročno država zadužuje kroz obveznice, kredite i zajmove.

Jedan od vrlo popularnih načina zaduživanja države je izdanje državnih vrijednosnica. Državne vrijednosnice kao instrument fiskalne politike omogućuju, ukoliko se efikasno upravlja javnim dugom, povoljan razvoj financijskog tržišta i cijelog gospodarstva. Prinosi na državne obveznice[76] predstavljaju referentne stope u određivanju cijena izdanja korporativnih obveznica, ali i drugih financijskih instrumenata na tržištu. Pojednostavljeno, izdavatelji

[74] Kolačević, S.: *Javni dug kao ključna varijabla ostvarenja ciljeva ekonomske politike*, Ekonomski pregled, Vol. 62(2011.), No. 3/4, str. 208

[75] Raspudić Golomejić, Z.: *Koordinacija upravljanja javnim dugom i vođenja monetarne politike u Hrvatskoj*, Financijska teorija i praksa, Vol. 31(2007.), No. 2, str.153

[76] Dragić, K., Lamza, D.: *Determinante dizajniranja domaćeg tržišta državnih vrijednosnica*, Ekonomski pregled, Vol. 55(2004.), No.11/12, str.967-1001

obveznica uobičajeno cijenu izračunavaju uračunavajući na prinos (cijenu) državne obveznice premiju rizika izdavatelja ili grane industrije kojoj izdavatelj pripada. Država ima najmanji rizik izdavatelja. Državna izdanja nisu osigurana bilo kakvom pokretninom ili nekretninom, već investitori na osnovi dostignutoga stupnja povjerenja i održavanja kredibiliteta ta izdanja vrednuju niskorizičnima.

Na tržištu duga susreću se različite interesne skupine koje imaju različite ciljeve. Sudionike tržišta državnih vrijednosnica možemo podijeliti u tri skupine: emitente, intermedijare (posrednike) i investitore. Na slici 8. dan je prikaz tržišta duga te je opisana struktura sudionika i njihovi ciljevi.

Slika 8: Ukupno tržište duga

EMITENTI VRIJEDNOSNICA	FINANCIJSKI INTERMEDIJARI	INSTITUCIONALNI I INDIVIDUALNI INVESTITORI
Država, državne agencije, poduzeća, banke, općine, gradovi, institucije	Dileri, brokeri, banke, agencije za kreditni rejting	Države, mirovinski fondovi, osiguravajuća društva, razni fondovi, banke, institucije, domaćinstva
CILJEVI		
• Prodaja vrijednosnica uz prihvatljivu tržišnu cijenu. • Uredna i likvidna sekundarna tržišta za vrijednosnice. • Učinkovito mijenjanje i prilagođavanje odluka prema tržišnim okolnostima pri novim emislijama vrijednosnica. • Kreiranje i emitiranje vrijednosnica koje najbolje odgovaraju potrebama tržišta.	• Pružanje usluga za stvaranje primarnog tržišta – ponude na aukcijama, vođenje emisija i distribucija. • Omogućavanje urednog poslovanja na sekundarnom tržištu. • Pružanje usluga za upravljanje imovinom i rizikom. • Omogućavanje trgovine vrijednosnicama.	• Kupnja vrijednosnica s različitim odnosima rizika i povrata uz prihvatljivu cijenu. • Diversifikacija uz niske troškove. • Promjena prethodnih odluka uz niske troškove. • Pristup instrumentima zaštite od rizika – financijske izvedenice(derivati). • Dobivanje informacija kao što je kreditni rejting, itd. Uz niske troškove.

Izvor: Sumpor, M.: *Tržište državnih vrijednosnica*, Ekonomski pregled, Vol. 53(2002.), No.3/4, str. 320

Zaduživanje države izdavanjem državnih vrijednosnica umjesto kreditima ima nekoliko prednosti: stvaranje utrživih financijskih instrumenata najvišeg stupnja sigurnosti u zemlji,

koji služe kao referentna mjera (engl. benchmark) za sve ostale emisije vrijednosnih papira i kretanja cijena na financijskom tržištu. Na taj način postoje jednostavni mehanizmi kontrole te ih je moguće preoblikovati i koristiti u mnogim varijacijama. Istovremeno služe i monetarnoj politici za operacije na otvorenom tržištu. [77] Kratkoročni instrumenti služe fiskalnoj politici kao način premošćivanja sezonskih utjecaja u tijeku proračunske godine, odnosno financiranja tekućih izdataka u uvjetima nižih proračunskih prihoda. Dugoročni instrumenti su pak zanimljivi institucionalnim investitorima jer se radi o sigurnom plasmanu sredstava.

4.1. Tržište javnog duga u Republici Hrvatskoj

4.1.1. Primarno tržište javnog duga u Republici Hrvatskoj[78]

Hrvatska se na tržištu kapitala zadužuje izdavanjem trezorskih zapisa (kratkoročno) aukcijama i izdavanjem obveznica (dugoročno) sindikatom. Takav odabir tehnika prodaje u skladu je s dobrom međunarodnom praksom jer su izdanja obveznica na domaćem tržištu sporadična i prilično velika.
Tehnike izdavanja javnog duga su: aukcije trezorskih zapisa, izravna kratkoročna i dugoročna kreditna zaduživanja, izdavanja obveznica sindikatom.

Aukcije trezorskih zapisa Ministarstva financija

Sudjelovanje na aukcijama trezorskih zapisa Ministarstva financija otvoreno je svim pravnim i fizičkim osobama rezidentima Republike Hrvatske. Hrvatska narodna banka ne sudjeluje na aukcija jer za potrebe upravljanju likvidnošću bankovnog sustava na tržištu izdaje blagajničke zapise.
U zemljama s razvijenijim tržištem državnih vrijednosnica središnje banke obično ne izdaju vlastite vrijednosnice nego na likvidnost bankovnog sustava utječu putem operacija državnim vrijednosnicama na sekundarnom tržištu i repo poslovima.

[77] Sumpor, M.: *Tržište državnih vrijednosnica*, Ekonomski pregled, Vol. 53(2002.), No.3/4, str. 320
[78] Prema Bajo, A.: *Primarno tržište javnog duga u Hrvatskoj*, Ekonomski fakultet u Zagrebu, dostupno na http://web.efzg.hr/dok//FIN/abajo//4.1.%20PRIMARNO%20TRZISTE%20JAVNOG%20DUGA%20U%20HRVATSKOJ.pdf

Trezorske zapise, kratkoročne vrijednosne papire, izdaje Ministarstvo financija od 1996. godine. Izdaje ih po jedinstvenoj cijeni koja se ostvari na aukciji. Ministarstvo financija izdaje trezorske zapise s rokom dospijeća od 91, 182 i 364 dana. Međutim postoje izuzeci, na primjer Ministarstvo financija je izdalo 2008. i 2012. godine trezorske zapis s dospijećem od dvije godine.

Izdavanje obveznica sindikatom

Obveznice se na domaćem tržištu izdaju putem sindikata domaćih banaka kao aranžera izdanja. Bankovni sindikat (sindikat banaka) je grupa investicijskih banaka koja prema sporazumu upisnika kupuje novo izdanje vrijednosnica velike vrijednosti od emitenta s ciljem raspodjele investitorima na primarnom financijskom tržištu. Vlada na prijedlog Ministarstva financija donosi odluku o izdanju obveznica uz aranžere izdanja čija je ponuda najbolja. Banka gestor je banka članica konzorcija koja preuzima ulogu voditelja konzorcija, organizira njegovo poslovanje i istupa prema drugim osobama u ime konzorcija. Kod sličnih "bankovnih sindikata" odgovara joj pojam vodećeg menadžera (lead manager) koji u slučaju izdavanja obveznica ili odobravanja sindiciranih kredita zastupa banke članove sindikata pri ugovaranju kredita sa zajmotražiocem ili rukovodi plasmanom izdanja obveznica.
Pokrovitelji izdanja obveznica su vodeće banke, a njihova je zadaća priprema i provedba izdavanjem državnih obveznica za izdavatelja te upis i uplata svih obveznica (ili samo onih koje ostanu neupisane). Memorandumom o razumijevanju banke koje nastupaju kao sindikat utvrđuju interne odnose i zajedno odgovaraju na zahtjev Ministarstva financija za ponudu aranžiranja izdavanja obveznica.

Slika 9. Vremenski tijek upisa jednog izdanja obveznica



*Izvor:*http://web.efzg.hr/dok//FIN/abajo//4.1.%20PRIMARNO%20TRZISTE%20JAVNOG%20DUGA%20U%20HRVATSKOJ.pdf (14.4. 2014.)

Izdavanje obveznica na međunarodnom tržištu

Hrvatske obveznice koje su izdane u inozemstvu denominirane su u valuti zemlje u kojoj su izdane. Inozemne obveznice dobivaju i karakteristična imena u skladu s mjestom izdanja, kao što su primjerice „Yankee bonds“ u SAD-u ili „Samurai bonds“ u Japanu. Najznačajnija su tržišta u Zuerichu, New Yorku, Tokiju, Frankfurtu, Londonu i Amsterdamu.

Euroobveznice

Euroobveznice (u odnosu na vanjske) izdaju se istodobno u mnogim financijskim središtima. Izdavatelji mogu ponuditi obveznice denominirane, na primjer u američkim dolarima koje se u isto vrijeme prodaju preko financijskih posrednika u više zemalja.
Izraz „euroobveznice“ predstavlja izdanje koje istodobno privlači sredstva investitora iz različitih dijelova svijeta.
Izdavanje euroobveznice obavlja se putem sindikata banaka. Izdavatelj nudi odabranoj investicijskoj banci upravljanje izdavanjem obveznica. Obično se radi o međunarodnoj financijskoj instituciji (J. P. Morgan, Deutsche Bank i dr.). Postupak je sličan kao i kod sindikata domaćih banaka.

4.1.2. Sekundarno tržište javnog duga u Republici Hrvatskoj

Sekundarno tržište (engl. secondary market) je tržište na kojem se obavlja stalna kupoprodaja već emitiranih vrijednosnih papira koji su u ruke investitora došli rasprodajom na primarnom tržištu. Zove se i transakcijsko tržište[79]. Na njemu se ne prikupljaju nova novčana sredstva već se samo mijenja vlasnik vrijednosnice, tj. vrijednosnice se preprodaju.
Radi zaštite sudionika uređuje se pravno i organizacijski, te ima ulogu podešavanja likvidnosti. Postoje dvije kategorije tržišta koje čine sekundarno tržište: službena burza i OTC tržište. U posljednjih nekoliko godina pridaje se sve veća pozornost potrebi postojanja razvijenog, organiziranog i dobro funkcionirajućeg sekundarnog tržišta za državne

[79] http://www.poslovni.hr/leksikon/sekundarno-trziste-101115.aspx (21. 04. 2014.)

vrijednosnice. Efikasno sekundarno tržište[80] za državne vrijednosnice važno je za plasman novih emisija i dugoročno gledano neophodno za ostvarenje ciljeva države.
Primarni dileri[81] su skupine dilera državnim vrijednosnicama koje vlasti obično zadužuju da na tržištima državnim vrijednosnicama budu specijalistički posrednici između vlasti i tržišta. Primarni dileri obično imaju posebna prava poslovanja sa središnjom bankom na otvorenom tržištu ili imaju povlastice u davanju ponuda na primarnim aukcijama. U zamjenu za ta posebna prava, primarni su dileri obično obvezni sudjelovati na primarnom tržištu i obavljati usluge oblikovanja tržišta na sekundarnom tržištu, a također su obvezni održavati standarde minimalnog kapitala i stručnog ljudskog kapitala.
Institucionalni okvir uspostave sustava primarnih dilera utvrđen je Zakonom o tržištu vrijednosnih papira. Osnovna uloga posrednika državnim vrijednosnicama je plasiranje vrijednosnica na sekundarno tržište i uspostavljanje likvidnosti.
U Hrvatskoj se u ulozi primarnih dilera pojavljuju vodeće poslovne banke koje su preuzele obvezu stalnog isticanja kupovne i prodajne cijene državnih vrijednosnica. Banke obavljaju dobrovoljne kotacije kupovnih i prodajnih cijena državnih vrijednosnica putem telefona ili Bloomberg elektronskog sustava. Iako kotacije nisu obvezujuće, kotirane cijene obično se poštuju za transakcije do milijun kuna.

Novčano tržište[82]

Hrvatsko međubankovno tržište predstavlja trgovinsku strukturu za obavljanje transakcija trezorskim zapisima. Kratkoročnim trezorskim zapisima Ministarstva financija trguje se uglavnom na primarnom tržištu.
U odnosu na državne obveznice kojima se aktivno trguje i na sekundarnom tržištu, trezorski zapisi kupljeni na primarnom tržištu obično se drže do dospijeća. Do trgovine dolazi samo u iznimnim slučajevima kada pojedina banka iscrpi sve druge mogućnosti dolaska do likvidnosti pa je prisiljena na prodaju trezorskih zapisa (što je u pravilu rijetko).
Trgovina trezorskim zapisima demotivira investitore ne samo zbog kratkih rokova dospijeća nego i postojećih velikih razlika kupovne i prodajne cijene.
Kao najveći investitori pojavljuju se stambene štedionice, investicijski fondovi, mirovinski fondovi, mirovinska osiguravajuća društva i osiguravajuća društva.

[80] Sumpor, M.: *Tržište državnih vrijednosnica*, Ekonomski pregled, Vol. 53(2002.), No.3/4, str. 329
[81] http://www.hnb.hr/mmf/kodeks-dobrih-praksa/1-dio/h-dodatak-3.pdf (28.04. 2012.)
[82] Prema *http://e-lib.efst.hr/2012/2101815.pdf,* str.39 (21.4.2014.)

Promet državnim obveznicama podijeljen je u tri skupine:
- redovni promet - transakcije koje se sklapaju putem trgovinskog sustava Zagrebačke burze unošenjem naloga za kupnju i prodaju vrijednosnih papira,
- prijavljeni promet - promet dužničkim vrijednosnicama iznad 3 milijuna kuna između skrbnika ili člana tržišta novca i ovlaštenih brokerskih kuća i
- institucionalni promet - između dva institucionalna ulagatelja (npr. banaka, osiguravatelja, itd., za koje ne postoji količinski limiti) u koji je uključen promet samo s dužničkim vrijednosnicama.

Prijeboj i namira

Središnje klirinško depozitarno društvo (SKDD) obavlja poslove prijeboja i namire transakcija vrijednosnim papirima. 2005. godine SKDD je dobio status posebnog sudionika u hrvatskom sustavu velikih plaćanja. SKDD sudjeluje u sustavu obračuna međubankovnih platnih transakcija u realnom vremenu.
Uvođenjem sustava isporuke uz plaćanje u stvarnom vremenu osigurana je ključna pretpostavka za razvitak tržišne infrastrukture, proširenje sekundarnog tržišta i uključivanja većeg broja investitora.

4.1.3. Pregled i razvoj tržišta javnog duga u Republici Hrvatskoj

Raspadom SFRJ i hrvatskim osamostaljivanjem javni dug Republike Hrvatske bio je u mnogome određen naslijeđenim dugom iz bivše SFRJ. Unutarnji dug je pretežito stvoren nakon što je Republika Hrvatska preuzela potraživanja od hrvatskih građana za devizne depozite kod domaćih banka. Devizna štednja je nakon toga pretvorena u obveznicu koju su dobile banke i koja se amortizirala polugodišnje sljedećih deset godina. S obzirom da je RH imala problema s otplaćivanjem prva dva anuiteta duga iz devizne štednje izdane su nakon toga dvije trogodišnje, anuitetne obveznice u njemačkim markama: polovicom 1995. JDA (u iznosu od 157 milijuna DEM) i krajem 1995. JDB (u iznosu od 147 milijuna DEM), koje su zapravo prve lokalne obveznice RH kojima se aktivnije trgovalo na domaćem tržištu. Vanjski javni dug nastao je preuzimanjem dijela obveza bivše SFRJ prema članicama Pariškog i Londonskog kluba. Potpisivanje Pariškog i Londonskog sporazuma bilo je ključno za početak

samostalnog nastupanja RH na svjetskom tržište kapitala te je otvorilo prostor za prva izdanja na međunarodnom obvezničkom tržištu.[83]
Nakon toga je od 1996. do danas uslijedilo intenzivnije sudjelovanje RH na međunarodnom i domaćem tržištu kapitala. U tom razdoblju možemo ustvrditi sljedeće[84]:
1. Od 1996. do 2000. RH je izdavala obveznice isključivo na eurobond tržištu. U istom razdoblju Ministarstvo financija RH je otvaralo različite segmente međunarodnog tržišta, odnosno izdavalo obveznice u raznim valutama. Tako u tom vremenu možemo nabrojati dolarsko, eursko, samurai i matador izdanje.

2. U 2000. pojavljuju se prva domaća izdanja, ali izdavatelj nije Ministarstvo financija već državne agencije DAB (Državna agencija za osiguranje štednih uloga i sanaciju banaka) i HZZO (Hrvatski zavod za zdravstveno osiguranje). Razlog je u tome što bi DAB-u i HZZO-u bilo teško izdati obveznice na međunarodnom tržištu, a izdanja su bila dovoljno malena da ih može apsorbirati domaće tržište na kojem u to doba prevladavaju banke.

3. U razdoblju od 2001-2004. RH se redovito pojavljuje na inozemnom tržištu po jednim eurskim izdanjem godišnje, a uz to su izdane dvije dodatne samurai obveznice. Istovremeno su reforma mirovinskog sustava i uvođenje drugog stupa, jačanje investicijskih fondova, osiguranje i drugih institucionalnih investitora otvorili prostor brzom razvoju lokalne eurske krivulje prinosa. Krivulja se puni redom s petogodišnjim, desetogodišnjim i petnaestogodišnjim izdanjima u valutnoj klauzuli, ali se izdaje i prva lokalna kunska obveznica.

4. Od 2005. do 2007. dominiraju kunska izdanja i intezivno se razvija kunska krivulja prinosa dok RH, kako odlukom Vlade da smanji vanjski dug, tako i velikom domaćom potražnjom nestaje sa međunarodnog eurobond tržišta.

5. Nakon izbijanja svjetske financijske krize i njenog prelijevanja u Hrvatsku 2008. je prva godina od 1996. godine u kojem nije bilo niti jednog obvezničkog izdanja RH. U toj godini je međunarodno tržište kapitala funkcioniralo s mnogo smetnji dok je hrvatsko tržište pogođeno padom svih vrsti financijske imovine i bijegom investitora iz financijskih ulaganja. RH je ipak

[83] Prema Korunić, T., Bjelkanović, D.: *Trebaju li Hrvatskoj primarni dileri za državne vrijednosnice?*, Intercapital Zagreb, 2011.
[84] Ibidem, str. 7

financirala dospjele obveze kroz par velikih izdanja trezorskih zapisa koje su pretežito upisivali mirovinski fondovi i uz pomoć kredita kod domaćih banaka.

6. U 2009. i 2010. RH se vraća na obvezničko tržište prvo kroz eursko i dolarsko izdanje na eurobond tržištu 2009., a potom kroz dva kunska izdanja na domaćem tržištu i jednom eurskom izdanju na eurobond tržištu u 2010.[85]

7. 2011. godina je je obilježena s dva domaća izdanja u kunama i eurima te dva međunarodna izdanja u dolarima i eurima. Također su provedene trezorske aukcije u svim mjesecima osim u travnju. 2012. godinu karakterizira daljnje državno zaduženje kroz trezorske zapise i obveznice. Početak godine je obilježen izdavanjema euroobveznica Republike Hrvatske u iznosu od 1,5 milijardi dolara s rokom dospijeća od 5 godina. Radi zaštite od međuvalutnih tečajnih promjena, uplate te sve isplate kamata i glavnice obveznica konvertirat će se u eure prema fiksnom tečaju 1,3110 dolara za jedan euro. U svim mjesecima su provedene aukcije trezorskih zapisa te je ponovno kao 2008. Ministarstvo financija izdalo dvogodišnje trezorske zapise.

8. U 2013. godini su osim redovitih aukcija trezorskih zapisa bila četiri izdanja obveznica. Ovu godinu je svakako obilježilo ukupno najobilnije zaduživanje dotad zabilježeno. Izdane su dvije euroobveznice u iznosu od po 1,5 i 1,75 milijardi dolara s rokom dospijeća od 10 godina uz konverziju prema fiksnom tečaju. Na domaćem tržištu je izdana petogodišnja kunska obveznica od 2,75 milijardi kuna te obveznica u iznosu od 1,4 milijardi eura s rokom dospijeća od 11 godina.

U sljedećem dijelu je prikazan pregled uvrštenih vrijednosnih papira i volumena trgovanja u 2013. godini i prvom kvartalu 2014. godine.

[85] http://www.mfin.hr

Slika 10. Tržišna kapitalizacija u 2013. godini u milijunima kuna

(Tržišna kapitalizacija u milijunima kuna)	2012	2013	% promjene
Promet unutar knjige ponuda			
Dionice	2.914.904.102	2.717.015.796	-6,8%
Obveznice	285.319.563	225.255.671	-21,1%
Prava	160	0	-
Komercijalni zapisi	49.800	2.124.588	4166,2%
Strukturirani proizvodi	51.764.819	169.616.476	227,7%
Blok promet dionica	192.446.362	343.922.729	78,7%
Blok promet dužničkih v.p.	409.457.471	348.763.598	-14,8%
Sveukupni promet	**3.853.942.277**	**3.806.698.858**	-1,2%
Volumen unutar knjige ponuda			
Dionice	43.212.507	40.354.585	-6,6%
Obveznice	155.786.656	67.232.083	-56,8%
Prava	160	0	-
Komercijalni zapisi	60.000	993.903	1556,5%
Strukturirani proizvodi	783.817	4.004.478	410,9%
Blok volumen dionica	5.382.102	9.672.430	0,0%
Blok volumen dužničkih v.p.	236.604.700	144.126.240	-39,1%
Sveukupni volumen	**441.829.942**	**266.383.719**	-39,7%
OTC transakcije			
Promet	19.315.895.961	18.240.181.545	-5,6%
Volumen	8.696.728.039	9.450.807.205	8,7%
Broj transakcija	2.528	2.634	4,2%
CROBEX©	1.740,39	1.794,28	3,1%
CROBEX10®	971,56	994,85	2,4%
CROBEXplus®	898,47	987,83	9,9%
CROBEXindustrija®	914,60	1.106,90	21,0%
CROBEXkonstrukt®	917,23	787,26	-14,2%
CROBEXnutris®	869,70	879,75	1,2%
CROBEXtransport®	957,46	1.169,80	22,2%
CROBEXturist®	820,85	1.155,00	40,7%
CROBIS©	103,75	99,16	-4,4%
CROBIStr©	122,13	123,26	0,9%
Ukupni broj transakcija	280.990	255.046	-9,2%
Broj aktivnih vrijednosnih papira	**367**	**368**	**0,3%**
Broj dana trgovanja	250	249	-0,4%
Tržišna kapitalizacija			
Dionice	127.795,6	118.980,3	-6,9%
Obveznice	62.007,2	64.273,2	3,7%
Strukturirani proizvodi	1.771,5	493,9	-72,1%
Ukupno	**191.574,3**	**183.747,5**	-4,1%
Prosječni dnevni			
Promet	15.415.769	15.287.947	-0,8%
Volumen	1.767.320	1.069.814	-39,5%
Broj transakcija	1.124	1.024	-8,9%

Izvor: http://zse.hr/(2.5.2014.)

Na slici 10. vidljivo je kako promet vrijednosnim papirima u RH značajno opao u 2013. godini u odnosu na 2012.godinu. Prema periodičnim godišnjim izvješćima Zagrebačke burze pad prometa vrijednosnim papirima prisutan je svake godine od 2010. godine. Na sljedećim slikama dani su popisi uvrštenih papira u 2013. godini.

Slika 11. Popis uvrštenih obveznica u 2013. godini

Simbol	Izdavatelj	Nominala	Broj izdanih	Kamata	Dospijeće
	Službeno tržište				
ATGR-O-169A	Atlantic Grupa d.d.	1 HRK	115.000.000	6,750	20.9.2016
FNOI-D-141A	Fond za naknadu oduzete imovine	1 EUR	3.733.790	0,000	1.1.2014
FNOI-D-147A	Fond za naknadu oduzete imovine	1 EUR	3.733.790	0,000	1.7.2014
FNOI-D-151A	Fond za naknadu oduzete imovine	1 EUR	3.733.790	0,000	1.1.2015
FNOI-D-157A	Fond za naknadu oduzete imovine	1 EUR	3.733.790	0,000	1.7.2015
FNOI-D-161A	Fond za naknadu oduzete imovine	1 EUR	3.733.790	0,000	1.1.2016
FNOI-D-167A	Fond za naknadu oduzete imovine	1 EUR	3.733.790	0,000	1.7.2016
FNOI-D-171A	Fond za naknadu oduzete imovine	1 EUR	3.733.790	0,000	1.1.2017
FNOI-D-177A	Fond za naknadu oduzete imovine	1 EUR	3.733.790	0,000	1.7.2017
FNOI-D-181A	Fond za naknadu oduzete imovine	1 EUR	3.733.790	0,000	1.1.2018
FNOI-D-187A	Fond za naknadu oduzete imovine	1 EUR	3.733.790	0,000	1.7.2018
FNOI-D-191A	Fond za naknadu oduzete imovine	1 EUR	3.733.790	0,000	1.1.2019
FNOI-D-197A	Fond za naknadu oduzete imovine	1 EUR	3.733.790	0,000	1.7.2019
GDRI-O-167A	Grad Rijeka	1 EUR	24.574.513	4,125	18.7.2016
GDST-O-15BA	Grad Split	1 EUR	8.100.000	4,750	27.11.2015
GDST-O-177A	Grad Split	1 EUR	8.200.000	6,000	8.7.2017
HEP-O-17CA	HEP d.d.	1 HRK	700.000.000	6,500	7.12.2017
HOTR-O-173A	Hospitalija trgovina d.o.o.	1 EUR	7.715.000	9,750	23.3.2017
HP-O-155A	HP - Hrvatska pošta d.d.	1 HRK	400.000.000	7,750	31.5.2015
IGH-O-176A	Institut IGH d.d.	1 EUR	10.000.000	9,000	6.6.2017
INGR-O-11CA	Ingra d.d.	1 HRK	162.425.661	6,125	6.12.2016
JDGL-O-166A	Jadran - galenski laboratorij d. d.	1 HRK	140.000.000	4,800	10.6.2016
JRLN-O-17AA	Jadrolinija d.d.	1 EUR	11.000.000	6,500	24.10.2017
MTEL-O-137A	Metronet telekomunikacije d.d.	1 EUR	19.800.000	12,000	17.7.2019
OIV-O-14BA	Odašiljači i veze d.o.o.	1 HRK	100.000.000	7,250	20.11.2014
OPTE-O-142A	OT-Optima telekom d.d.	1 HRK	250.000.000	9,125	1.2.2014
PLOR-O-157A	Plodine d. d.	1 HRK	62.170.000	9,000	10.7.2015
RHMF-O-142A	Ministarstvo financija Republike Hrvatske	1 EUR	650.000.000	5,500	10.2.2014
RHMF-O-157A	Ministarstvo financija Republike Hrvatske	1 EUR	350.000.000	4,250	14.7.2015
RHMF-O-15CA	Ministarstvo financija Republike Hrvatske	1 HRK	5.500.000.000	5,250	15.12.2015
RHMF-O-167A	Ministarstvo financija Republike Hrvatske	1 HRK	3.500.000.000	5,750	22.7.2016
RHMF-O-172A	Ministarstvo financija Republike Hrvatske	1 HRK	5.500.000.000	4,750	8.2.2017
RHMF-O-17BA	Ministarstvo financija Republike Hrvatske	1 HRK	4.000.000.000	6,250	25.11.2017
RHMF-O-187A	Ministarstvo financija Republike Hrvatske	1 HRK	2.750.000.000	5,250	10.7.2018
RHMF-O-19BA	Ministarstvo financija Republike Hrvatske	1 EUR	500.000.000	5,375	29.11.2019
RHMF-O-203A	Ministarstvo financija Republike Hrvatske	1 HRK	5.000.000.000	6,750	5.3.2020
RHMF-O-203E	Ministarstvo financija Republike Hrvatske	1 EUR	1.000.000.000	6,500	5.3.2020
RHMF-O-227E	Ministarstvo financija Republike Hrvatske	1 EUR	1.000.000.000	6,500	22.7.2022
RHMF-O-247E	Ministarstvo financija Republike Hrvatske	1 EUR	750.000.000	5,750	10.7.2024
RIBA-O-177A	Erste&Steiermärkische Bank d. d.	1 EUR	80.000.000	6,500	18.7.2017
RIBA-O-17BA	Erste&Steiermärkische Bank d. d.	1 HRK	300.000.000	5,875	23.11.2017
RPRO-O-181A	Rijeka promet d. d.	1 HRK	192.000.000	6,813	25.1.2018
SCVI-O-14CA	ŠC Višnjik d.o.o.	1 EUR	9.600.000	8,810	23.12.2014
	Redovito tržište				
GROS-O-17AA	Grad Osijek	1 HRK	25.000.000	5,500	30.10.2017
GRVI-O-17AA	Grad Vinkovci	1 HRK	42.000.000	5,500	23.10.2017

Izvor: http://zse.hr/(2.5.2014.)

Slika 12. Popis uvrštenih komercijalnih zapisa u 2013. godini

Simbol	Izdavatelj	Nominala	Broj izdanih
	Službeno tržište		
PTKM-M-416A	Petrokemija d.d.	1 HRK	30.570.000
PTKM-M-416E	Petrokemija d.d.	1 EUR	1.100.000
PTKM-M-430A	Petrokemija d.d.	1 HRK	3.080.586
PTKM-M-444A	Petrokemija d.d.	1 HRK	29.781.232
Simbol	**Izdavatelj**	**Nominala**	**Broj izdanih**
	Redovito tržište		
MTEL-M-418E	Metronet telekomunikacije d.d.	1 EUR	2.190.000
ZGMN-M-448A	Zagreb-Montaža d.o.o.	1 HRK	13.050.000

Izvor: http://zse.hr/(2.5.2014.)

Slika 13. Popis uvrštenih prava u 2013. godini

Simbol	Izdavatelj	Nominala	Broj izdanih
RHMJ-A-A	Republika Hrvatska	1 HRK	400.000.000
RHMF-A-A	Republika Hrvatska	1 HRK	644.750.000

Izvor: http://zse.hr/(2.5.2014.)

U prvom kvartalu 2014. godine u odnosu na posljednji kvartal 2013. godine , bilježi se veći promet, ali i pad indeksa. No, usporedba s prvim tromjesečjem 2013. godine otkriva da je ova godina započela manjim ukupnim prometom i padom indeksa.[86]

[86] Prema http://zse.hr/UserDocsImages/reports/ZSE-1Q2014.pdf (2.5.2014.)

Slika 14. Popis uvrštenih obveznica u prvom kvartalu 2014. godine

Simbol	Izdavatelj	Nominala	Broj izdanih	Kamata	Dospijeće
	Službeno tržište				
ATGR-O-169A	Atlantic Grupa d.d.	1 HRK	115.000.000	6,750	20.9.2016
FNOI-D-147A	Fond za naknadu oduzete imovine	1 EUR	3.733.790	0,000	1.7.2014
FNOI-D-151A	Fond za naknadu oduzete imovine	1 EUR	3.733.790	0,000	1.1.2015
FNOI-D-157A	Fond za naknadu oduzete imovine	1 EUR	3.733.790	0,000	1.7.2015
FNOI-D-161A	Fond za naknadu oduzete imovine	1 EUR	3.733.790	0,000	1.1.2016
FNOI-D-167A	Fond za naknadu oduzete imovine	1 EUR	3.733.790	0,000	1.7.2016
FNOI-D-171A	Fond za naknadu oduzete imovine	1 EUR	3.733.790	0,000	1.1.2017
FNOI-D-177A	Fond za naknadu oduzete imovine	1 EUR	3.733.790	0,000	1.7.2017
FNOI-D-181A	Fond za naknadu oduzete imovine	1 EUR	3.733.790	0,000	1.1.2018
FNOI-D-187A	Fond za naknadu oduzete imovine	1 EUR	3.733.790	0,000	1.7.2018
FNOI-D-191A	Fond za naknadu oduzete imovine	1 EUR	3.733.790	0,000	1.1.2019
FNOI-D-197A	Fond za naknadu oduzete imovine	1 EUR	3.733.790	0,000	1.7.2019
GDRI-O-167A	Grad Rijeka	1 EUR	24.574.513	4,125	18.7.2016
GDST-O-15BA	Grad Split	1 EUR	8.100.000	4,750	27.11.2015
GDST-O-177A	Grad Split	1 EUR	8.200.000	6,000	8.7.2017
HEP-O-17CA	HEP d.d.	1 HRK	700.000.000	6,500	7.12.2017
HOTR-O-173A	Hospitalija trgovina d.o.o.	1 EUR	7.715.000	9,750	23.3.2017
HP-O-155A	HP - Hrvatska pošta d.d.	1 HRK	400.000.000	7,750	31.5.2015
IGH-O-176A	Institut IGH d.d.	1 EUR	10.000.000	9,000	6.6.2017
INGR-O-11CA	Ingra d.d.	1 HRK	162.425.661	6,125	6.12.2016
JDGL-O-166A	JADRAN - GALENSKI LABORATORIJ d. d.	1 HRK	140.000.000	4,800	10.6.2016
JRLN-O-17AA	Jadrolinija	1 EUR	11.000.000	6,500	24.10.2017
MTEL-O-137A	Metronet telekomunikacije d.d.	0,5 EUR	19.800.000	4,500	19.3.2022
OIV-O-14BA	Odašiljači i veze d.o.o.	1 HRK	100.000.000	7,250	20.11.2014
PLOR-O-157A	Plodine d. d.	1 HRK	62.170.000	9,000	10.7.2015
RHMF-O-157A	Ministarstvo financija Republike Hrvatske	1 EUR	350.000.000	4,250	14.7.2015
RHMF-O-15CA	Ministarstvo financija Republike Hrvatske	1 HRK	5.500.000.000	5,250	15.12.2015
RHMF-O-167A	Ministarstvo financija Republike Hrvatske	1 HRK	3.500.000.000	5,750	22.7.2016
RHMF-O-172A	Ministarstvo financija Republike Hrvatske	1 HRK	5.500.000.000	4,750	8.2.2017
RHMF-O-17BA	Ministarstvo financija Republike Hrvatske	1 HRK	4.000.000.000	6,250	25.11.2017
RHMF-O-187A	Ministarstvo financija Republike Hrvatske	1 HRK	2.750.000.000	5,250	10.7.2018
RHMF-O-19BA	Ministarstvo financija Republike Hrvatske	1 EUR	1.000.000.000	5,375	29.11.2019
RHMF-O-203A	Ministarstvo financija Republike Hrvatske	1 HRK	5.000.000.000	6,750	5.3.2020
RHMF-O-203E	Ministarstvo financija Republike Hrvatske	1 EUR	1.000.000.000	6,500	5.3.2020
RHMF-O-227E	Ministarstvo financija Republike Hrvatske	1 EUR	1.000.000.000	6,500	22.7.2022
RHMF-O-247E	Ministarstvo financija Republike Hrvatske	1 EUR	1.400.000.000	5,750	10.7.2024
RIBA-O-177A	Erste&Steiermärkische Bank d. d.	1 EUR	80.000.000	6,500	18.7.2017
RIBA-O-17BA	Erste&Steiermärkische Bank d. d.	1 HRK	300.000.000	5,875	23.11.2017
RPRO-O-181A	Rijeka promet d. d.	1 HRK	192.000.000	6,813	25.1.2018
SCVI-O-14CA	ŠC Višnjik d.o.o.	1 EUR	9.600.000	8,810	23.12.2014
	Redovito tržište				
GROS-O-17AA	Grad Osijek	1 HRK	25.000.000	5,500	30.10.2017
GRVI-O-17AA	Grad Vinkovci	1 HRK	42.000.000	5,500	23.10.2017

Izvor: http://zse.hr/(2.5.2014.)

Vidljivo je da su uvrštene 22 državne obveznice (s rokom dospijeća najdulje do 2024. godine), 5 municipalnih (s rokom dopijeća najdulje do 2017. godine) i 15 korporativnih obveznica (s rokom dospijeća najdulje do 2018. godine uz iznimku Metronet telekomunikacije d.d. s rokom dospijeća 2022. godine).

Slika 15. Popis uvrštenih komercijalnih zapisa u prvom kvartalu 2014. godine

Simbol	Izdavatelj	Nominala	Broj izdanih
	Službeno tržište		
PTKM-M-416A	Petrokemija d.d.	1 HRK	30.570.000
PTKM-M-416E	Petrokemija d.d.	1 EUR	1.100.000
PTKM-M-430A	Petrokemija d.d.	1 HRK	3.080.586
PTKM-M-444A	Petrokemija d.d.	1 HRK	29.781.232
	Redovito tržište		
MTEL-M-418E	Metronet telekomunikacije d.d.	1 EUR	2.190.000
ZGMN-M-348A	Zagreb-Montaža d.o.o.	1 HRK	30.000.000

Izvor: http://zse.hr/(2.5.2014.)

Slika 16. Popis uvrštenih prava u prvom kvartalu 2014. godine

Simbol	Izdavatelj	Nominala	Broj izdanih
RHMJ-A-A	Republika Hrvatska	1 HRK	400.000.000
RHMF-A-A	Republika Hrvatska	1 HRK	644.750.000

Izvor: http://zse.hr/(2.5.2014.)

4.2. Tržište korporativnog duga u Republici Hrvatskoj

Početak razvoja tržišta korporativnih obveznica u Republici Hrvatskoj vezuje se uz emisiju obveznica Belišća d.d. i Plave lagune d.d., 2002. godine. Nakon prodaje na primarnom tržištu, te su dvije emisije uvrštene na Zagrebačku i Varaždinsku burzu, a obveznicama se manje trguje na sekundarnom tržištu. Ipak, važno je naglasiti da je spomenute emisije obveznica gotovo u cijelosti otkupila Privredna banka Zagreb d.d., koja je ujedno bila i aranžer i agent izdanja. Stoga se može postaviti pitanje je li se radilo o javnoj emisiji obveznica u pravom smislu riječi.[87] Prva značajna godina bila je 2004. Ona je uslijedila nakon što su godinu ranije zabilježene velike aktivnosti na tržištu korporativnih dužničkih vrijednosnih papira.[88] U 2005.

[87] Miloš, D.: *Perspektive razvoja Hrvatskog tržišta korporacijskih obveznica*, Financijska teorija i praksa, Vol. 28(2004.), No. 4, str. 418
[88] http://www.ericsson.com/hr/etk/novine/kom080907/22.pdf (3.5.2014.)

godini tržište je utihnulo da bi se tijekom 2006. godine diglo sa osam kunskih izdanja ukupne nominalne vrijednosti 2,8 milijardi kuna. U 2007. god izdane su kunske obveznice sedam korporacija ukupne nominalne vrijednosti 1,3 milijardi kuna. Svjetska financijska kriza je značajno utjecala na broj izdanih korporativnih obveznica od 2008. do 2010.godine. Sveukupno je u tom razdoblju emitirano šest obveznica ukupne nominalne vrijednosti 0,9 milijardi kuna. Oporavak je uslijedio 2011. godine kada je emitirano pet korporativnih obveznica ukupne nominalne vrijednosti 1,9 milijardi, vraćajući taj obim izdanja u predkrizne godine. U 2012. godini emitirane je 5 obveznica ukupne nominalne vrijednosti 1 milijarde kuna. 2013. godine i u prvom tromjesečju 2014. godine tržište je ponovno utihnulo s tek dva skromna izdanja korporativnih obveznica.

Iako u Hrvatskoj postoje zadovoljavajući institucionalni i zakonski okviri, oživljavanje tržišta korporativnih obveznica nailazi na probleme.

Da bi korporativne dužničke vrijednosnice ozbiljnije zaživjele u Hrvatskoj, tržište mora biti likvidnije. S aspekta investitora, glavna prednost te vrste papira je da on u svakome trenutku može ranije iz njih izaći. No zbog nelikvidnosti tržišta, investitori u Hrvatskoj to ne mogu, stoga se ti dužnički papiri pretvaraju u imovinu koja se drži do dospijeća.[89] Nadalje, hrvatsko tržište je premalo da bi se stvorio veći interes stranih ulagača koji bi se zanimali za takve vrste dužničkih papira. Rješenja se vide u ekonomskom oporavku koji bi mogao podići interes stranih ulagača ili da kompanije počnu listati dužničke vrijednosne papire i na regionalnim tržištima što povlači za sobom povezivanje burzi u regiji koje si jedino velike kompanije i regionalni igrači mogu priuštiti.

Primjeri nedovoljne likvidnosti nisu samo sporadični slučajevi već ih je posljednjih godina sve više. Metronet telekomunikacije d.d. dvaput nije moglo isplatiti polugodišnje kamate za obveznicu MTEL-O-137A. Prvi put za razdoblje 17.1.2013.- 16.7.2013.[90] te drugi put za razdoblje 17.7.2013.- 16.1.2014.[91] Kompanija je prošla kroz postupak predstečajne nagodbe i restrukturiranja uz promjenu vlasničke i dioničke strukture.[92] Optima telekom d.d. nije

[89] http://www.poslovni.hr/mobile/burze/krediti-ce-jos-godinama-biti-popularniji-od-obveznica-199111 (3.5.2014.)
[90] http://www.banka.hr/hrvatska/metronet-ne-moze-isplatiti-dospjele-kamate (3.5.2014.)
[91] http://www.poslovni.hr/burze/metronet-opet-ne-moze-isplatiti-kamatu-261538 (3.5.2014.)
[92] http://www.ictbusiness.info/telekomunikacije/metronet-zavrsio-predstecajnu-nagodbu (3.5.2014.)

isplatila glavnicu i kamatu po dospijeću 1.2.2014. za obveznicu OPTE-O-142A.[93] Kompanija je također prošla kroz postupak predstečajne nagodbe i restrukturiranja.[94]

Institut IGH bio je u nemogućnosti isplatiti iznos dospjele kamate za obveznicu oznake IGH-O-176A, za razdoblje 6.12. 2012. - 5. 6. 2013.[95] Kompanija je također prošla kroz postupak predstečajne nagodbe i restrukturiranja.[96] Ingra d.d. nije bila u mogućnosti uplatiti iznos kamata po obveznici INGR-O-11CA tijekom 2012. i 2013. godine zbog blokade računa.[97] Kompanija upravo prolazi kroz postupak predstečajne nagodbe.[98] Nexe grupa d.d. nije bila u mogućnosti isplatiti iznos polugodišnje kamate po obveznici NEXE-O-13CA za razdoblje od 10. lipnja 2012. do 10. prosinca 2012.[99] Kompanija upravo prolazi kroz postupak predstečajne nagodbe.[100]

Ovakvi slučajevi svakako pridonose da je investicijska atmosfera u hrvatskoj i dalje krajnje negativna i depresivna.[101] Ipak, okončanjem predstečajnih nagodbi te financijskim i vlasničkim restrukturiranjem, ispunjene su pretpostavke za nastavak poslovanja korporacija uz posljedično poboljšanje investicijske klime.

Pregled emisija svih korporativnih obveznica na domaćem tržištu po godinama dan je u sljedećoj tablici:

Tablica 1. Popis uvrštenih korporativnih obveznica po godinama

Simbol	**Izdavatelj**	**Nominala**	**Broj izdanih**	**Kamata**	**Dospijeće**
2002.					
BLSC-O-051A	Belišće d.d.	1 EUR	17.000.000	7,375%	17.1.2005.
PLAG-O-048A	Plava laguna d.d.	1 EUR	12.000.000	6,750%	25.8.2004.
2003.					

[93] http://www.poslovni.hr/burze/optima-telekom-nije-isplatila-obveznicu-263005 (3.5.2014.)
[94] http://www.poslovni.hr/domace-kompanije/optima-telekom-smanjio-gubitak-za-85-milijuna-kuna-270448 (3.5.2014.)
[95] http://www.poslovni.hr/domace-kompanije/igh-ne-moze-isplatiti-kamatu-za-obveznicu-243340 (3.5.2014.)
[96] http://www.business.hr/kompanije/institut-igh-sklopio-predstecajnu-nagodbu (3.5.2014.)
[97] http://www.tportal.hr/biznis/novaciulaganje/266237/Ingra-i-IGH-ne-mogu-platiti-kamatu-po-obveznicama.html (3.5.2014.)
[98] http://www.poslovnipuls.com/2014/03/27/ingra-na-korak-do-sklapanja-predstecajne-nagodbe/ (3.5.2014.)
[99] http://www.banka.hr/hrvatska/ocekivano-nexe-grupa-ne-moze-isplatiti-kamatu-na-obveznice (3.5.2014.)
[100] http://www.poslovni.hr/tag/nexe-nexe-grupa-dd-1214 (3.5.2014.)
[101] Prema http://www.poslovni.hr/mobile/burze/krediti-ce-jos-godinama-biti-popularniji-od-obveznica-199111 (3.5.2014.)

BNAI-O-22CA	Bina Istra d.d.	1 EUR	210.000.000	8%	15.12.2022.
HYBA-O-086A	Hypo Alpe-Adria Bank d.d.	1 HRK	150.000.000	6,500%	6.6.2008.
2004.					
AGKR-O-074A	AGROKOR d.d.	1 EUR	230.000.000	11%	3.4.2007.
ATGR-O-074A	ATLANTIC GRUPA d.o.o.	1 EUR	15.000.000	5,750%	13.7.2007.
PLVA-O-115A	PLIVA d.d.	1 EUR	75.000.000	5,750%	12.5.2011.
PODR-O-072A	Podravka d.d.	1 EUR	27.000.000	5%	20.2.2007.
2005.					
BLSC-O-091	Belišće d.d.	1 EUR	8.000.000	5,500%	14.1.2009.
MDKA-O-087A	Medika d.d.	1 EUR	16.500.000	4,500%	11.7.2008.
2006.					
ATGR-O-11CA	ATLANTIC GRUPA d.d.	1 HRK	115.000.000	5,750%	6.12.2011.
HEP-O-13BA	HRVATSKA ELEKTROPRIVREDA d.d.	1 HRK	500.000.000	5%	29.11.2013.
INGR-O-11CA	Ingra d.d.	1 HRK	250.000.000	6,125%	6.12.2011.
NEXE-O-116A	NEXE GRUPA d.d.	1 HRK	750.000.000	5,500%	14.6.2011.
PODR-O-115A	Podravka d.d.	1 HRK	375.000.000	5,125%	17.5.2011.
RBA-O-112A	Raiffeisenbank Austria d.d.	1 HRK	600.000.000	4,125%	13.2.2011.
HOTR-O-941A	Hospitalija trgovina d.o.o.	1 HRK	75.000.000	8,250%	5.10.2009.
MTEL-O-097A	Metronet telekomunikacije d.d.	1 HRK	120.000.000	8,500%	28.7.2009.
2007.					
HEP-O-17CA	HEP d.d.	1 HRK	700.000.000	6,500%	7.12.2017.
JDGL-O-126A	Jadran - galenski laboratorij d. d.	1 HRK	125.000.000	5,650%	11.6.2012.
JDRA-O-129A	Jadranka d. d.	1 HRK	75.000.000	6,480%	13.9.2012.
JRLN-O-12AA	Jadrolinija d.d.	1 HRK	70.000.000	6,500%	25.10.2012.
OIV-O-14BA	Odašiljači i veze d.o.o.	1 HRK	100.000.000	7,250%	20.11.2014.
OPTE-O-	OT-optima telekom	1 HRK	250.000.000	9,125%	1.2.2014.

142A	d.d.				
SEM-O-101A	Linijska nacionalna plovidba d.d.	1 HRK	15.000.000	7,000%	12.1.2010.
2008.					
PLOR-O-133A	Plodine d. d.	1 HRK	100.000.000	9,000%	4.3.2013.
RPRO-O-181A	Rijeka promet d. d.	1 HRK	192.000.000	6,813%	25.1.2018.
SCVI-O-14CA	ŠC Višnjik d.o.o.	1 EUR	9.600.000	8,813%	23.12.2014.
2009.					
MTEL-O-137A	Metronet telekomunikacije d.d.	1 EUR	19.800.000	12,000%	17.7.2013.
HP-O-127A	HP - Hrvatska pošta d.d.	1 EUR	41.000.000	9,000%	1.7.2012.
2010.					
HOTR-O-173A	Hospitalija trgovina d.o.o.	1 EUR	7.715.000	9,750%	23.3.2017.
2011.					
JDGL-O-166A	Jadran - galenski laboratorij d. d.	1 HRK	140.000.000	6,173%	10.6.2016.
RIBA-O-177A	Erste&Steiermarkische Bank d. d.	1 EUR	80.000.000	6,500%	18.7.2017.
INGR-O-11CA	Ingra d.d.	1 HRK	162.425.661	6,125%	6.12.2016.
NEXE-O-13CA	Nexe grupa d.d.	1 EUR	120.000.000	7,825%	10.12.2013.
ATGR-O-169A	Atlantic grupa d.d.	1 HRK	115.000.000	6,750%	20.9.2016.
2012.					
HP-O-155A	HP - Hrvatska pošta d.d.	1 HRK	400.000.000	7,750%	31.5.2015.
MTEL-O-137A	Metronet telekomunikacije d.d.	1 EUR	19.800.000	12,000%	17.7.2019.
JRLN-O-17AA	Jadrolinija d.d.	1 EUR	11.000.000	6,500%	24.10.2017.
RIBA-O-17BA	Erste&Steiermärkische Bank d. d.	1 HRK	300.000.000	5,875%	23.11.2017.
IGH-O-176A	Institut IGH d.d.	1 EUR	10.000.000	9,000%	6.6.2017.
2013.					
PLOR-O-157A	Plodine d. d.	1 HRK	62.170.000	9,000%	10.7.2015.

Izvor: Autor[102]

[102] Prema periodičnim godišnjim izvješćima Zagrebačke burze dostupno na http://zse.hr/

Bitno je istaknuti da korporacije u godini dospijeća kada trebaju isplatiti posljednju kamatu s glavnicom, najčešće emitiraju nove obveznice. Pregled svih uvrštenih korporativnih obveznica u prvom tromjesečju 2014. godine dan je u tablici 2.

Tablica 2. Popis uvrštenih korporativnih obveznica u prvom kvartalu 2014. godine

Simbol	Izdavatelj	Nominala	Broj izdanih	Kamata	Dospijeće
ATGR-O-169A	Atlantic Grupa d.d.	1 HRK	115.000.000	6,750%	20.9.2016.
HEP-O-17CA	HEP d.d.	1 HRK	700.000.000	6,500%	7.12.2017.
HOTR-O-173A	Hospitalija trgovina d.o.o.	1 EUR	7.715.000	9,750%	23.3.2017.
HP-O-155A	HP - Hrvatska pošta d.d.	1 HRK	400.000.000	7,750%	31.5.2015.
IGH-O-176A	Institut IGH d.d.	1 EUR	10.000.000	9,000%	6.6.2017.
INGR-O-11CA	Ingra d.d.	1 HRK	162.425.661	6,125%	6.12.2016.
JDGL-O-166A	JADRAN - GALENSKI LABORATORIJ d. d.	1 HRK	140.000.000	4,800%	10.6.2016.
JRLN-O-17AA	Jadrolinija	1 EUR	11.000.000	6,500%	24.10.2017.
MTEL-O-137A	Metronet telekomunikacije d.d.	0,5 EUR	19.800.000	4,500%	19.3.2022.
OIV-O-14BA	Odašiljači i veze d.o.o.	1 HRK	100.000.000	7,250%	20.11.2014.
PLOR-O-157A	Plodine d. d.	1 HRK	62.170.000	9,000%	10.7.2015.
RIBA-O-177A	Erste&Steiermärkische Bank d. d.	1 EUR	80.000.000	6,500%	18.7.2017.
RIBA-O-17BA	Erste&Steiermärkische Bank d. d.	1 HRK	300.000.000	5,875%	23.11.2017.
RPRO-O-181A	Rijeka promet d. d.	1 HRK	192.000.000	6,813%	25.1.2018.
SCVI-O-14CA	ŠC Višnjik d.o.o.	1 EUR	9.600.000	8,810%	23.12.2014.

Izvor: Autor[103]

[103] Prema http://zse.hr/UserDocsImages/reports/ZSE-1Q2014.pdf

5. IZRAČUN KRIVULJE PRINOSA

5.1. Formiranje ulaznih podataka i izračun krivulje prinosa za RH na određeni datum

Upravo je malobrojnost izdanja kunskih državnih vrijednosnica i slabo trgovanje istima na sekundarnom tržištu glavni razlog zašto još uvijek nema službene procjene krivulje prinosa u Hrvatskoj.

Za izračun krivulje prinosa na tržištu kapitala u Hrvatskoj korišteni su podaci s Tržišta novca Zagreb, gdje se mogu pronaći podaci o trgovanju blagajničkim i trezorskim zapisima, te podaci s Reutersa gdje su pronađeni podaci o trgovanju obveznicama.

Krivulja prinosa se izračunava za datum 17. veljače 2014. godine. Na taj dan trezorskim zapisima se nije trgovalo, no blagajničkim zapisima jest. U sljedećoj tablici je prikazano trgovanje blagajničkim zapisima te prekonoćna, tjedna te mjesečna kamatna stopa na kunske blagajničke zapise.

Tablica 3. Trgovina blagajničkim zapisima na dan 17.2.2014.

ponuda u mil. kn	*promjena u %*	*potražnja u mil. kn*	*promjena u %*
324,50	0,78	64,50	4,03

promet	*u mil. kn*	*promjena u %*	*kamatna stopa u %*	*promjena u %*
prekonoćni	14,00	0,00	0,53	0,00
1 tjedan	6,50	- 76,79	3,50	90,22
1 mjesec	24,00	-	2,25	-
ukupno:	44,50	5,95	1,89	35,00

Izvor: www.trzistenovca.hr (4.5.2014.)

Iz baze Reuters skinuti su podaci o trgovanju kunskim obveznicama na isti datum i prikazani su u sljedećoj tablici.

Tablica 4. Podaci o trgovanju obveznicama[104]

Ticker	Market of Issue	Domicile	Issue date	Coupon	Maturity	Issue Price	Amount Outstanding	Principal Currency	Rating ID	Rating	Bid Yield	Ask Yield	Bid Price	Ask Price
RHMF-T-409A	CROAT	HR	28.2.2013.	0	27.2.2014.	97,6290	9,670 E+08	HRK	FCH	BBB-	0,621	0,219	99,983	99,994
RHMF-T-410A	CROAT	HR	7.3.2013.	0	6.3.2014.	97,5820	1,106 E+09	HRK	FCH	BBB-	2,106	1,999	99,902	99,907
RHMF-T-411A	CROAT	HR	14.3.2013.	0	13.3.2014.	97,5330	1,567 E+09	HRK	FCH	BBB-	1,401	0,807	99,908	99,947
RHMF-T-412A	CROAT	HR	21.3.2013.	0	20.3.2014.	97,5570	5,380 E+08	HRK	FCH	BBB-	1,651	1,049	99,860	99,911
RHMF-T-414A	CROAT	HR	4.4.2013.	0	3.4.2014.	97,5350	6,450 E+08	HRK	FCH	BBB-	1,202	0,049	99,852	99,994
RHMF-T-418A	CROAT	HR	2.5.2013.	0	1.5.2014.	97,6660	1,372 E+09	HRK	FCH	BBB-	0,651	0,165	99,870	99,967
RHMF-T-422A	CROAT	HR	31.5.2013.	0	29.5.2014.	97,5380	4,080 E+08	HRK	FCH	BBB-	0,789	0,3	99,782	99,917
RHMF-T-423A	CROAT	HR	6.6.2013.	0	5.6.2014.	97,5640	1,122 E+09	HRK	FCH	BBB-	0,891	0,399	99,737	99,882
RHMF-O-15CA	CROAT	HR	15.12.2005.	5,25	15.12.2015.	100,000	5,500 E+09	HRK	-	-	3,241	2,686	103,510	104,510
RHMF-O-167A	CROAT	HR	22.7.2011.	5,75	22.7.2016.	99,1460	3,500 E+09	HRK	FCH	BBB-	3,675	3,254	104,760	105,760
RHMF-O-172A	CROAT	HR	8.2.2007.	4,75	8.2.2017.	98,7480	5,500 E+09	HRK	FCH	BBB-	4,383	4,024	101,010	102,010
RHMF-O-17BA	CROAT	HR	24.11.2010.	6,25	25.11.2017.	99,9980	4,000 E+09	HRK	FCH	BBB-	4,563	4,282	105,760	106,760
RHMF-O-187A	CROAT	HR	10.7.2013.	5,25	10.7.2018.	99,9570	2,750 E+09	HRK	FCH	BBB-	4,799	4,548	101,760	102,760
RHMF-O-203A	CROAT	HR	5.3.2010.	6,75	5.3.2020.	98,5750	5,000 E+09	HRK	MDY	Ba1	5,233	5,048	107,760	108,760

Izvor: Autor prema http://www.reuters.com (4.5.2014.)

Odavde su iskorišteni sljedeći podaci o obveznicama: tiker, datum izdanja, kupon, izračunata su kuponska plaćanja i datum zadnjeg kuponskog plaćanja, datum za koji se izračunava krivulja prinosa te broj dana od zadnjeg kuponskog plaćanja.

[104] Navedeni datum je jedan od boljih datuma u 2014.godini kada je zabilježena trgovina s čak 14 obveznica.

Nadalje prikazan je datum dospijeća, te ponuđena i potraživana cijena iz čega je izračunata čista cijena kao prosjek prve dvije. Čista cijena nije ona po kojoj bi investitor kupio obveznicu osim ako to nije na datum plaćanja kupona, jer broj dana do plaćanja idućeg kupona se smanjuje. Kroz ovo vrijeme imatelj obveznice je zaradio proporciju idućeg kuponskog plaćanja. Stoga je potrebno platiti trenutnom imaocu njegovo pravo na iduće kuponsko plaćanje, tj. na stečenu kamatu. Kamatu smo izračunali služeći se sljedećom formulom:

stečena kamata = kupon · (broj dana od zadnjeg kuponskog plaćanja)/
(broj dana između kuponskih plaćanja).

Tek zbrajanjem čiste cijene i stečene kamate dobije se cijena koju će investitor platiti za obveznicu.

Tablica 5. Izračun cijene obveznice

Tiker	Datum izdavanja	Kupon	Kuponska plaćanja	Datum zadnjeg kuponskog plaćanja	Datum idućeg kupona	Današnji datum	Broj dana od zadnjeg kuponskog plaćanja	Datum dospijeća	Ponuđena cijena	Potraživana cijena	Čista cijena	Stečena kamata	Cijena plaćanja
RHMF-T-409A	28.2.2013.	0	0		27.2.2014.	17.2.2014.		27.2.2014.	99,983	99,994	99,9885	0	99,9885
RHMF-T-410A	7.3.2013.	0	0		6.3.2014.	17.2.2014.		6.3.2014.	99,902	99,907	99,9045	0	99,9045
RHMF-T-411A	14.3.2013.	0	0		13.3.2014.	17.2.2014.		13.3.2014.	99,908	99,947	99,9275	0	99,9275
RHMF-T-412A	21.3.2013.	0	0		20.3.2014.	17.2.2014.		20.3.2014.	99,860	99,911	99,8855	0	99,8855
RHMF-T-414A	4.4.2013.	0	0		3.4.2014.	17.2.2014.		3.4.2014.	99,852	99,994	99,923	0	99,923
RHMF-T-418A	2.5.2013.	0	0		1.5.2014.	17.2.2014.		1.5.2014.	99,870	99,967	99,9185	0	99,9185
RHMF-T-422A	31.5.2013.	0	0		29.5.2014.	17.2.2014.		29.5.2014.	99,782	99,917	99,8495	0	99,8495
RHMF-T-423A	6.6.2013.	0	0		5.6.2014.	17.2.2014.		5.6.2014.	99,737	99,882	99,8095	0	99,8095
RHMF-O-15CA	15.12.2005.	5,25	2,625	15.12.2013.	15.6.2014.	17.2.2014.	64	15.12.2015.	103,510	104,510	104,01	0,9230769	104,9330769
RHMF-O-167A	22.7.2011.	5,75	2,875	22.1.2014.	22.7.2014.	17.2.2014.	26	22.7.2016.	104,760	105,760	105,26	0,4107143	105,6707143
RHMF-O-172A	8.2.2007.	4,75	2,375	8.2.2014.	8.8.2014.	17.2.2014.	10	8.2.2017.	101,010	102,010	101,51	0,1304945	101,6404945
RHMF-O-17BA	24.11.2010.	6,25	3,125	25.11.2013.	25.5.2014.	17.2.2014.	84	25.11.2017.	105,760	106,760	106,26	1,4423077	107,7023077
RHMF-O-187A	10.7.2013.	5,25	2,625	10.1.2014.	10.7.2014.	17.2.2014.	38	10.7.2018.	101,760	102,760	102,26	0,5480769	102,8080769
RHMF-O-203A	5.3.2010.	6,75	3,375	5.9.2013.	5.3.2014.	17.2.2014.	165	5.3.2020.	107,760	108,760	108,26	3,0597527	111,3197527

Kao što se može vidjeti, osam obveznica su nul-kupon obveznice s različitim vremenima dospijeća, a ostalih šest obveznica su kuponske obveznice. Potrebno je poredati obveznice s obzirom na vrijeme do dospijeća od najbližeg do najdaljeg i izračunati prinos do dospijeća. Najprije smo preuzeli podatke s Tržišta novca Zagreb (tablica 3) o vremenu i prinosu do dospijeća budući da su to najkraća vremena dospijeća te su prikazani u tablici 6. U istoj su

tablici za osam sljedećih nul-kupon obveznica u prvom stupcu prikazana je nominalna vrijednost obveznice, a u sljedećim današnja cijena, odnosno cijena plaćanja izračunata i prikazana u tablici 5, isplata po dospijeću i vrijeme do dospijeća koje računamo po kontinuiranom obračunu korištenjem funkcije Goal Seek[105] prema formuli

$$P = Ce^{-tR},$$

gdje P predstavlja današnju cijenu, t vrijeme do dospijeća, C nominalnu vrijednost obveznice i R traženi prinos do dospijeća.

Tablica 6. Prinos do dospijeća nul-kupon obveznica

	Nominalna vrijednost	Današnja cijena	Plaćanja	Vrijeme	Prinos do dospijeća	Sadašnja vrijednost
prekonoćni				0,002739726	0,0053	
1 tjedan				0,019230769	0,035	
1 mjesec				0,083333333	0,0225	
RHMF-T-409A	100	99,9885	100	0,02739726	0,004198075	99,98849909
RHMF-T-410A	100	99,9045	100	0,046575342	0,020509187	99,90452337
RHMF-T-411A	100	99,9275	100	0,065753425	0,011029667	99,92750245
RHMF-T-412A	100	99,8855	100	0,084931507	0,013487177	99,88551695
RHMF-T-414A	100	99,923	100	0,123287671	0,006249406	99,9229822
RHMF-T-418A	100	99,9185	100	0,2	0,004079076	99,91845174
RHMF-T-422A	100	99,8495	100	0,276712329	0,00544639	99,84940519
RHMF-T-423A	100	99,8095	100	0,295890411	0,006447724	99,8093999

Nakon izračuna prinosa do dospijeća za nul kupon obveznice potrebno je izračunati prinose do dospijeća za kuponske obveznice upotrebom Solvera[106]. Da bismo dobili što veći spektar parova vrijednosti vremena dospijeća i pripadajućih kamatnih stopa aproksimirat ćemo kamatne stope po kojima se diskontiraju preostala obveznička plaćanja, a koja nisu ,,pokrivena“ prethodno utvrđenim stopama prinosa (kamatnim stopama za kraća vremena dospijeća). Izračunate kamatne stope za svaku obveznicu redom se koriste kod ostalih

[105] Korištena funkcija Goal Seek se nalazi u programskom alatu MS Office Excel 2007.
[106] Korištena funkcija Solver se nalazi u programskom alatu MS Office Excel 2007 i upotrebljava se za kompliciranije izračune.

obveznica na način da ih prepišemo, a za preostala dospijeća nanovo računamo kamatne stope.[107] Rezultati za sve kuponske obveznice dani su u tablici 7.

Tablica 7. Izračunati prinosi do dospijeća za ostale kuponske obveznice

	Nominalna vrijednost	Današnja cijena	Plaćanja	Vrijeme	Prinos do dospijeća	Sadašnja vrijednost
RHMF-O-15CA	100	104,9330769	2,625	0,3246575	0,015010213	2,612239025
			2,625	0,8246575	0,019998062	2,582064685
			2,625	1,3246575	0,024929385	2,539730567
			102,625	1,8246575	0,029770363	97,19904164
						104,9330759
RHMF-O-167A	100	105,6707143	2,875	0,428767123	0,019998062	2,850453666
			2,875	0,928767123	0,024929385	2,809198135
			2,875	1,428767123	0,029770363	2,755276384
			2,875	1,928767123	0,030198894	2,712324566
			102,875	2,428767123	0,034772795	94,54346143
						105,6707142
RHMF-O-172A	100	101,6404945	2,375	0,472602739	0,019998062	2,352659284
			2,375	0,972602739	0,024929385	2,318107337
			2,375	1,472602739	0,029770363	2,273129507
			2,375	1,972602739	0,034772795	2,217553424
			2,375	2,472602739	0,035249729	2,176762891
			102,375	2,972602739	0,042212103	90,30228192
						101,6404944
RHMF-O-17BA	100	107,7023077	3,125	0,269863013	0,00544639	3,120410314
			3,125	0,769863013	0,019998062	3,07725669
			3,125	1,269863013	0,024929385	3,027621657
			3,125	1,769863013	0,029770363	2,964608013
			3,125	2,269863013	0,034934456	2,886768913
			3,125	2,769863013	0,042212103	2,780171292
			3,125	3,269863013	0,042942617	2,715613265
			103,125	3,769863013	0,044707785	87,12985742
						107,7023076
RHMF-O-187A	100	102,8080769	2,625	0,395890411	0,019998062	2,604299818
			2,625	0,895890411	0,024929385	2,567023096
			2,625	1,395890411	0,029770363	2,518150572
			2,625	1,895890411	0,030198894	2,478930216

[107] Detaljnije o proceduri računanja kamatnih stope pogledati u Aljinović, Z., Marasović, B.: *Matematički modeli u analizi razvoja hrvatskog financijskog tržišta*, Ekonomski fakultet u Splitu, 2012., str. 52-53

			2,625	2,395890411	0,034772795	2,415168581
			2,625	2,895890411	0,042212103	2,322953121
			2,625	3,395890411	0,044707785	2,25524397
			2,625	3,895890411	0,045358004	2,1998102
			102,625	4,395890411	0,047061205	83,44649666
						102,8080762
RHMF-O-203A	100	111,3197527	3,375	0,047945205	0,011029667	3,373215706
			3,375	0,547945205	0,019998062	3,33821917
			3,375	1,047945205	0,024929385	3,287971125
			3,375	1,547945205	0,029770363	3,222999455
			3,375	2,047945205	0,034934456	3,141974653
			3,375	2,547945205	0,042212103	3,030844217
			3,375	3,047945205	0,042942617	2,960945316
			3,375	3,547945205	0,044707785	2,879954666
			3,375	4,047945205	0,047061205	2,789588643
			3,375	4,547945205	0,047061205	2,724714202
			3,375	5,047945205	0,052074171	2,594847535
			3,375	5,547945205	0,052074171	2,528157246
			103,375	6,047945205	0,052074171	75,44632071
						111,3197526

Svi očitani ili izračunati parovi vrijednosti (T-t – vrijeme do dospijeća, R – prinos) obveznica kojima se trgovalo 17.2.2014., kao ulazni podaci u modelu su dani u tablici 8. u prva dva stupca. Nakon toga, u idući stupac upisuje se Nelson-Siegelova formula

$$R(t,T) = \beta_0 + (\beta_1 + \beta_2)\frac{1-e^{-\frac{T-t}{\tau}}}{\frac{T-t}{\tau}} - \beta_2 e^{-\frac{T-t}{\tau}}$$

te kvadrati odstupanja stvarnog prinosa do dospijeća od Nelson-Siegelovog, koji se sumiraju. Odabirom opcije Solver postavljenjem te sume za ciljnu ćeliju na minimum uz promjenu parametara $\beta_0, \beta_1, \beta_2, \tau$. Dobivene vrijednosti parametara su:

β_0 = 0.0612696, β_1 = -0.0448441, β_2 = -0.0879711, τ = 0.450748.

Tablica 8. Izračun krivulje prinosa Nelson-Siegelovim modelom

Vrijeme	Prinos do dospijeća	Nelson-Siegelov model	Kvadrati odstupanja	β_0	0,0612696
0,00274	0,0053	0,016295233	0,000120895	β_1	-0,0448441
0,019231	0,035	0,015544578	0,000378513	β_2	-0,0879711
0,083333	0,0225	0,013130895	8,77801E-05	τ	0,4507480
0,027397	0,004198075	0,015193534	0,0001209		

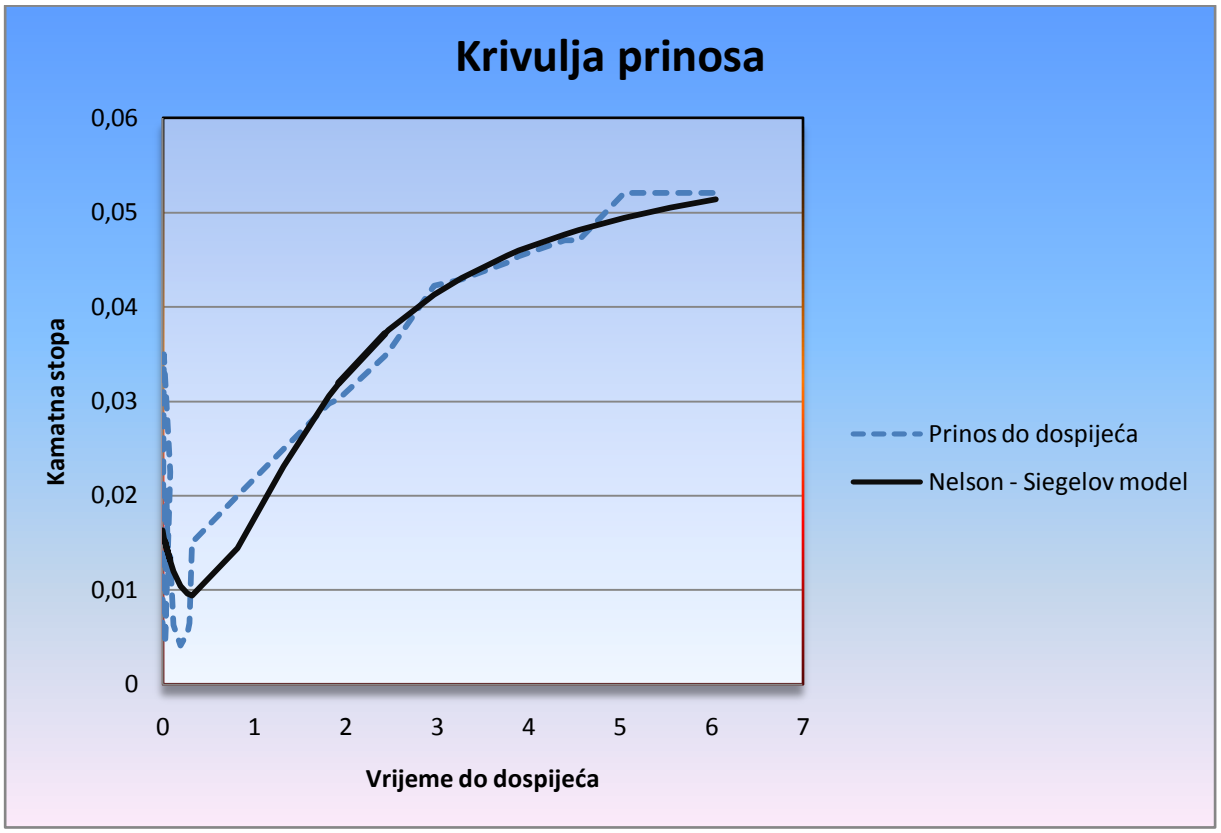
0,046575	0,020509187	0,014420862	3,70677E-05
0,065753	0,011029667	0,01371764	7,2252E-06
0,084932	0,013487177	0,013080201	1,6563E-07
0,123288	0,006249406	0,011988852	3,29412E-05
0,2	0,004079076	0,010452354	4,06187E-05
0,276712	0,00544639	0,009630665	1,75082E-05
0,29589	0,006447724	0,009518894	9,43209E-06
0,324658	0,015010213	0,009412905	3,13299E-05
0,824658	0,019998062	0,014443477	3,08534E-05
1,324658	0,024929385	0,0231242	3,25869E-06
1,824658	0,029770363	0,030568402	6,36866E-07
1,928767	0,030198894	0,03188001	2,82615E-06
2,428767	0,034772795	0,037135432	5,58205E-06
2,472603	0,035249729	0,037522914	5,16737E-06
2,972603	0,042212103	0,041278103	8,72355E-07
3,269863	0,042942617	0,043036269	8,77069E-09
3,769863	0,044707785	0,045413602	4,98178E-07
3,89589	0,045358004	0,045921309	3,17313E-07
4,39589	0,047061205	0,047656821	3,54758E-07
4,547945	0,047061205	0,048110433	1,10088E-06
5,047945	0,052074171	0,049411434	7,09017E-06
5,547945	0,052074171	0,050479334	2,54351E-06
6,047945	0,052074171	0,05137113	4,94267E-07
			0,000945982

Konačno možemo nacrtati krivulju prinosa procijenjenu na hrvatskom financijskom tržištu Nelson – Siegelovim modelom na datum 17.2.2014. Ona je grafički prikaz funkcije (slika 17) :

$$R(t,T) = 0.0612696 - 0.1328152\frac{1-e^{-\frac{T-t}{0.450748}}}{\frac{T-t}{0.450748}} - 0.0879711e^{-\frac{T-t}{0.450748}}.$$

Na istoj slici prikazane su i stvarne vrijednosti kamatnih stopa koje su poslužile kao ulazni podaci u modelu.

Slika 17. Krivulja prinosa



Krivulja prinosa je grbavog oblika s lokalnim (i globalnim) minimumom. Vrijednost dugoročne kamatne stope jest β_0 = 0.0612696. Zbroj vrijednosti parametara β_0 i β_1 je jednak kratkoročnoj kamatnoj stopi i iznosi 0.016425. β_1 kao razlika između kratkoročne i dugoročne stope iznosi β_1 = -0.0448441 te je tako potvrđen pozitivni nagib krivulje prinosa. Negativan predznak od β_2 = -0.0879711 znači da će se u vremenu τ pojaviti udubina, što je evidentno iz prethodne slike. Nastanak udubine odnosno lokalnog minimuma dominantno je pod utjecajem kratkoročnih kamatnih stopa blagajničkih zapisa što implicira da je međubankarsko tržište iznimno likvidno.

5.1.1. Statistička značajnost parametara primijenjenog modela

Izračun parametara $\beta_0, \beta_1, \beta_2, \tau$, u programu Statistica daje približno jednake vrijednosti onima dobivenim upotrebom Excela. Procjena parametara u Statistici izvršena je metodom najmanjih kvadrata upotrebom nelinearne procjene i upisivanjem funkcije :

v2=b0+(b1+b2)*(1-exp(-v1/t))/(v1/t)-b2*exp(-v1/t)

te odabirom Gauss-Newtonove iterativne metode. Vrijednosti procijenjenih parametara nalaze se u tablici 9, u prvom stupcu (Estimate), dok se empirijske signifikantnosti parametara nalaze u četvrtom stupcu (p-level). Rezultati pokazuju da su svi parametri značajni već pri signifikantnosti od 1%, odnosno da su značajne procijenjena dugoročna i kratkoročna kamatna stopa, nagib krivulje kao i pojavljivanje udubine u vremenu τ .

Tablica 9. Procijenjeni parametri upotrebom programskog alata Statistica

	Model is: v2=b0+(b1+b2)*(1-exp(-v1/t))/(v1/t)-b2*exp(-v1/t) Dep. Var. : Prinos do dospijeća Level of confidence: 95.0% (alpha=0.050)					
	Estimate	Standard error	t-value df = 23	p-value	Lo. Conf Limit	Up. Conf Limit
b0	0,061268	0,005472	11,19558	0,000000	0,049947	0,072588
b1	-0,044841	0,006932	-6,46837	0,000001	-0,059182	-0,030500
b2	-0,087976	0,018611	-4,72703	0,000092	-0,126477	-0,049476
t	0,450683	0,122302	3,68502	0,001226	0,197683	0,703684

Nadalje, provedeno je testiranje značajnosti modela analizom varijance (tablica 10). Promatrajući model kao cjelinu, statistički je značajan već pri signifikantnosti od 1%, što se očitava iz petog stupca (p-value). Izračunavanjem koeficijenta determinacije:

$$R^2 = \frac{SP}{ST} = \frac{0.027425}{0.028371} = 0.9667$$

zaključuje se da je 96.67% ukupnog zbroja kvadrata odstupanja stvarnih vrijednosti kamatnih stopa od procijenjenih Nelson-Siegelovim modelom protumačeno ovim modelom. Izračunat je i Spearmanov koeficijent korelacije ranga koji iznosi 0.8972 odnosno 89.72%, što upućuje na visoku korelaciju ranga stvarnih vrijednosti kamatnih stopa i vrijednosti procijenjenih Nelson-Siegelovim modelom.

Sve navedeno upućuje na zaključak da je procijenjeni model reprezentativan.

Tablica 10. Testiranje značajnosti modela analizom varijance

Effect	Model is: v2=b0+(b1+b2)*(1-exp(-v1/t))/(v1/t)-b2*exp(-v1/t) Dep. Var. : Prinos do dospijeća				
	1 Sum of Squares	2 DF	3 Mean Squares	4 F-value	5 p-value
Regression	0,027425	4,00000	0,006856	166,7015	0,000000
Residual	0,000946	23,00000	0,000041		
Total	0,028371	27,00000			
Corrected Total	0,007552	26,00000			
Regression vs.Corrected Total	0,027425	4,00000	0,006856	23,6035	0,000000

5.2. Formiranje ulaznih podataka i izračun krivulje prinosa korporativnih obveznica hrvatskog financijskog tržišta

Malobrojna izdanja obveznica i slaba trgovina istima na sekundarnom tržištu te nedovoljna likvidnost, o kojoj svjedoče predstečajne nagodbe zbog nemogućnosti plaćanja kupona, su razlozi koji otežavaju procjenu krivulje prinosa hrvatskih korporativnih obveznica. Usprkos navedenom, pokazat ćemo da je moguće konstruirati krivulju prinosa za odabrani portfelj korporativnih obveznica.

Krivulja prinosa se izračunava, kao i za državne obveznice, za datum 17. veljače 2014. godine. Tog datuma je bilo uvršteno 15 korporativnih obveznica prikazanih u tablici 2. Za procjenu krivulje prinosa u portfelj su uvrštene „likvidnije" obveznice većeg volumena izdanja. Kako na taj datum nije zabilježena zadovoljavajuća trgovina odabranim obveznicama, iste su interpolirane linearnom funkcijom[108] za odabrani period počevši od 17. veljače 2012. godine, dakle za period od dvije godine.

[108] Excelova funkcija Add trendline nudi različite tipove interpolacije, uz prikazivanje jednadžbe (linije trenda) i prognoze unaprijed i unazad za odabrani broj vremenskih perioda. Više o načinu izračuna odgovarajuće linearne funkcije pogledati u Prilog 1.

Iz baze Reuters skinuti su podaci o trgovanju i povijesni podaci o trgovanju potrebni za

Ticker	Issue date	Coupon	Maturity	Amount Outstanding	Principal Currency	Rating ID & Rating	Bid Price*	Ask Price*
HP-O-155A	21.5.2012.	7,75	21.5.2015.	400,0M	HRK	-	103,912	104,730
ATGR-O-169A	20.9.2011.	6,75	20.9.2016.	115,0M	HRK	-	104,000	106,398
RIBA-O-177A	18.7.2011.	6,5	18.7.2017.	80,0M	EUR	-	103,244	106,500
HEP-O-17CA	7.12.2007.	6,5	7.12.2017.	700,0M	HRK	S&P BB-	104,438	105,500
RIBA-O-17BA	23.11.2011.	5,875	23.11.2017.	300,0M	HRK	-	102,706	104,250

interpolaciju te interpolirane ponuđene i potraživane cijene odabranih korporativnih obveznica za datum 17.veljače 2014. godine i prikazani su u sljedećoj tablici:

Tablica 11. Podaci o odabranim korporativnim obveznicama

* cijene su interpolirane linearnom funkcijom za dvogodišnji period 17.2.2012.-17.2.2014.

Izvor: Autor prema http://www.reuters.com (27.5.2014.)

Odavde su iskorišteni sljedeći podaci o obveznicama: tiker, datum izdanja, kupon, izračunata su kuponska plaćanja i datum zadnjeg kuponskog plaćanja, datum za koji se izračunava krivulja prinosa te broj dana od zadnjeg kuponskog plaćanja.

Nadalje prikazan je datum dospijeća, te ponuđena i potraživana cijena iz čega je izračunata čista cijena kao prosjek prve dvije analogno izračunu kod državnih obveznica u prethodnom poglavlju.

Tablica 12. Izračun cijene korporativne obveznice

Tiker	**Datum izdavanja**	**Kupon**	**Kuponska plaćanja**	**Datum zadnjeg kuponskog plaćanja**	**Datum idućeg kupona**	**Današnji datum**	**Broj dana od zadnjeg kuponskog plaćanja**	**Datum dospijeća**	**Ponuđena cijena**	**Potraživana cijena**	**Čista cijena**	**Stečena kamata**	**Cijena plaćanja**
HP-O-155A	21.5.2012.	7,75	3,875	21.11.2013.	21.5.2014.	17.2.2014.	88	21.5.2015.	103,912	104,730	104,321	1,8684932	106,1894932
ATGR-O-169A	20.9.2011.	6,75	3,375	20.9.2013.	20.3.2014.	17.2.2014.	150	20.9.2016.	104,000	106,398	105,199	2,7739726	107,9729726
RIBA-O-177A	18.7.2011.	6,5	6,5	18.7.2013.	18.7.2014.	17.2.2014.	186	18.7.2017.	103,244	106,500	104,872	3,3123288	108,1843288
HEP-O-17CA	7.12.2007.	6,5	3,25	7.12.2013.	7.6.2014.	17.2.2014.	72	7.12.2017.	104,438	105,500	104,969	1,2821918	104,8622466
RIBA-O-17BA	23.11.2011.	5,875	2,9375	23.11.2013.	23.5.2014.	17.2.2014.	86	23.11.2017	102,706	104,250	103,478	1,3842466	106,2511918

Potrebno je poredati obveznice s obzirom na vrijeme do dospijeća od najbližeg do najdaljeg i izračunati prinos do dospijeća.

Da bismo dobili što veći spektar parova vrijednosti vremena dospijeća i pripadajućih kamatnih stopa povremeno ćemo se udaljiti od računanja kamatnih stopa za državne obveznice kada smo izračunate kamatne stope jedne obveznice prepisivali kod ostalih obveznica, pretpostavljajući monotoni rast kamatnih stopa s duljim vremenom do dospijeća. Ovdje i dalje pretpostavljamo monotoni rast kamatnih stopa s duljim vremenom dospijeća, no u Solver ćemo staviti dodatne uvjete tako da nam procijenjena kamatna stopa za određeno vrijeme do dospijeća bude u intervalu između izračunatih kamatnih stopa najbližeg kraćeg i prvog dužeg vremena do dospijeća. Na taj način ćemo dobiti više parova vrijednosti vremena dospijeća i pripadajućih kamatnih stopa, a time i bolju glatkoću krivulje prinosa.

Rezultati za sve korporativne obveznice iz portfelja dani su u tablici 13.

Tablica 13. Izračunati prinosi do dospijeća za korporativne obveznice iz portfelja

	Nominalna vrijednost	Današnja cijena	Plaćanja	Vrijeme	Prinos do dospijeća	Sadašnja vrijednost
HP-O-155A	100	106,1894932	3,875	0,25890411	0,019650739	3,855335395
			3,875	0,75890411	0,029176435	3,790142231
			103,875	1,25890411	0,041849849	98,54401555
						106,1894932
ATGR-O-169A	100	107,9729726	3,375	0,089041096	0,019650739	3,374973124
			3,375	0,589041096	0,029176435	3,317492429
			3,375	1,089041096	0,041849849	3,224632916
			3,375	1,589041096	0,041849849	3,157858775
			3,375	2,089041096	0,045714096	3,067449545
			103,375	2,589041096	0,045714096	91,83056581
						107,9729725
RIBA-O-177A	100	108,1843288	6,5	0,490410959	0,029176435	6,407657333
			6,5	1,490410959	0,041849849	6,106957554
			6,5	2,490410959	0,045714096	5,800217325
			106,5	3,490410959	0,04842158	89,86949659
						108,1843288
RIBA-O-17BA	100	104,8622466	2,9375	0,264383562	0,019650739	2,922278287
			2,9375	0,764383562	0,029176435	2,872713037
			2,9375	1,264383562	0,041849849	2,786105155
			2,9375	1,764383562	0,041849849	2,728411835
			2,9375	2,264383562	0,045714096	2,648510451
			2,9375	2,764383562	0,045714096	2,588632924
			2,9375	3,264383562	0,045714096	2,530109109
			102,9375	3,764383562	0,048421580	85,7854858

						104,8622466
HEP-O-17CA	100	106,2511918	3,25	0,302739726	0,019650739	3,230722954
			3,25	0,802739726	0,029176435	3,142631356
			3,25	1,302739726	0,041849849	3,077555263
			3,25	1,802739726	0,041886146	2,998087534
			3,25	2,302739726	0,045714096	2,925109574
			3,25	2,802739726	0,045714096	2,858974134
			3,25	3,302739726	0,045775757	2,769690832
			103,25	3,802739726	0,050603498	85,24841951
						106,2511912

Svi izračunati parovi vrijednosti (*T-t* – vrijeme do dospijeća, *R* – prinos) kao ulazni podaci u modelu su dani u tablici 14. u prva dva stupca. Nakon toga, u idući stupac upisuje se Nelson-Siegelova formula

$$R(t,T) = \beta_0 + (\beta_1 + \beta_2)\frac{1-e^{-\frac{T-t}{\tau}}}{\frac{T-t}{\tau}} - \beta_2 e^{-\frac{T-t}{\tau}}$$

te kvadrati odstupanja stvarnog prinosa do dospijeća od Nelson-Siegelovog, koji se sumiraju. Odabirom opcije Solver postavljenjem te sume za ciljnu ćeliju na minimum uz promjenu parametara $\beta_0, \beta_1, \beta_2, \tau$. Dobivene vrijednosti parametara su:

β_0 = 0.05250613, β_1 = -0.02755131, β_2 = -0.06232683, τ = 0.18212032.

Tablica 14. Izračun krivulje prinosa korporativnih obveznica Nelson-Siegelovim modelom

Vrijeme	Prinos do dospijeća	Nelson-Siegelov model	Kvadrati odstupanja	β_0	0.05250613
0,089041	0,01965073876193	0,019641309	8,89181E-11	β_1	-0.02755131
0,258904	0,01965073876193	0,019581628	4,77624E-09	β_2	-0.06232683
0,264384	0,01965073876193	0,019687098	1,32199E-09	τ	0.18212032
0,30274	0,01965073876193	0,020518065	7,52255E-07		
0,490411	0,02917643494213	0,025607164	1,27397E-05		
0,589041	0,02917643494213	0,028266779	8,27475E-07		
0,758904	0,02917643494213	0,032237558	9,37048E-06		
0,764384	0,02917643494213	0,032351311	1,00798E-05		
0,80274	0,02917643494213	0,033122887	1,55745E-05		
1,089041	0,04184984862929	0,037671474	1,74588E-05		
1,258904	0,04184984862929	0,039578813	5,1576E-06		

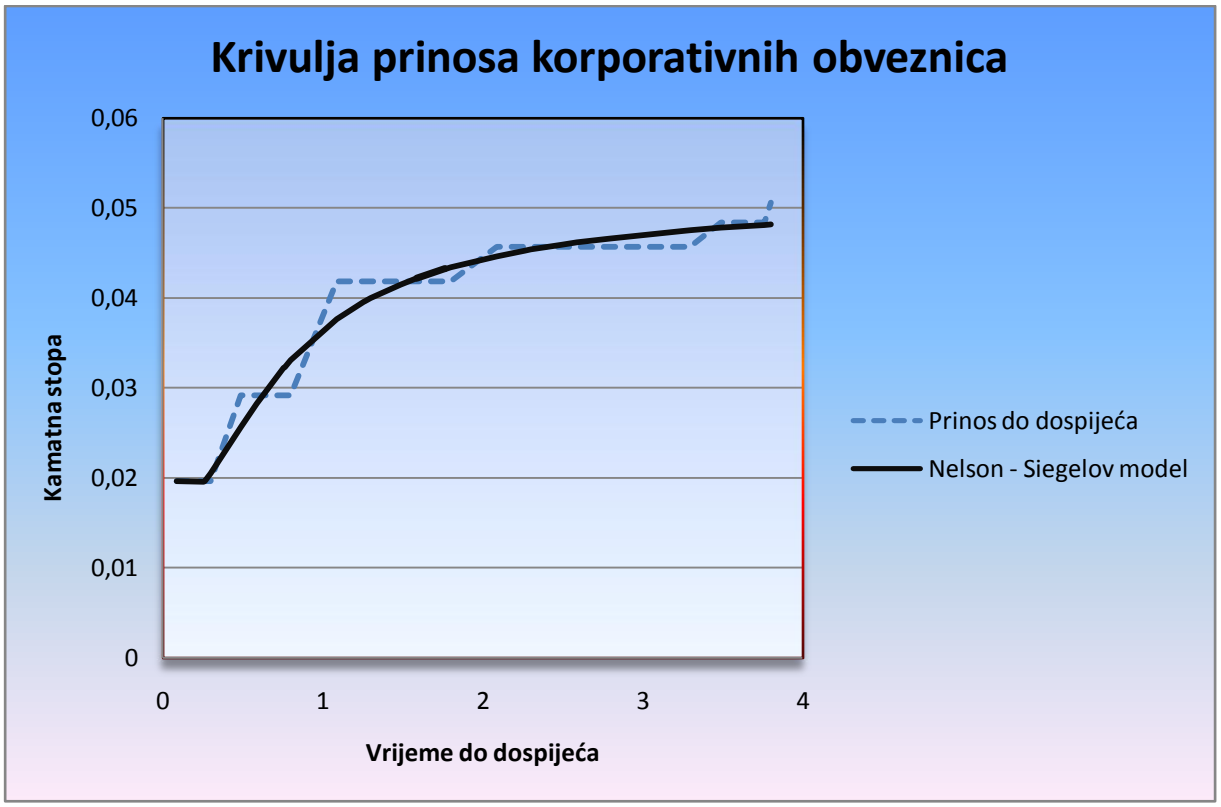
1,264384	0,04184984862929	0,039632885	4,91493E-06
1,30274	0,04184984862929	0,039999944	3,42215E-06
1,490411	0,04184984862929	0,041543963	9,35658E-08
1,589041	0,04184984862929	0,042216975	1,34782E-07
1,764384	0,04184984862929	0,043233316	1,91398E-06
1,80274	0,04188614571996	0,043429851	2,38303E-06
2,089041	0,04571409638009	0,044671383	1,08725E-06
2,264384	0,04571409638009	0,045277668	1,90469E-07
2,30274	0,04571409638009	0,045398023	9,99025E-08
2,490411	0,04571409638009	0,045933544	4,81574E-08
2,589041	0,04571409638009	0,046183898	2,20714E-07
2,764384	0,04571409638009	0,046584886	7,58275E-07
2,80274	0,04571409638009	0,046665917	9,05962E-07
3,264384	0,04571409638009	0,047491819	3,1603E-06
3,30274	0,04577575696650	0,047550053	3,14812E-06
3,490411	0,04842157952255	0,047816529	3,66087E-07
3,764384	0,04842157952255	0,048157839	6,95593E-08
3,80274	0,05060349763766	0,048201697	5,76864E-06
			0,000100653

Konačno možemo nacrtati krivulju prinosa korporativnih obveznica procijenjenu na hrvatskom financijskom tržištu Nelson – Siegelovim modelom na datum 17.2.2014. Ona je grafički prikaz funkcije (slika 18):

$$R(t,T) = 0.05250613 - 0.08987814\frac{1-e^{-\frac{T-t}{0.18212032}}}{\frac{T-t}{0.18212032}} + 0.06232683e^{-\frac{T-t}{0.18212032}}.$$

Na istoj slici prikazane su i stvarne vrijednosti kamatnih stopa koje su poslužile kao ulazni podaci u modelu.

Slika 18. Krivulja prinosa korporativnih obveznica



Krivulja prinosa je grbavog oblika s lokalnim minimumom. Vrijednost dugoročne kamatne stope jest β_0 = 0.05250613. Zbroj vrijednosti parametara β_0 i β_1 je jednak kratkoročnoj kamatnoj stopi i iznosi 0.02495482. β_1 kao razlika između kratkoročne i dugoročne stope iznosi β_1 = -0.02755131 te je tako potvrđen pozitivni nagib krivulje prinosa. Negativan predznak od β_2 = -0.06232683 znači da će se u vremenu τ pojaviti udubina, što je vidljivo iz prethodne slike.

5.2.1. Statistička značajnost parametara primijenjenog modela

Izračun parametara $\beta_0, \beta_1, \beta_2, \tau$, u programu Statistica daje približno jednake vrijednosti onima dobivenim upotrebom Excela. Procjena parametara u Statistici izvršena je metodom najmanjih kvadrata upotrebom nelinearne procjene i upisivanjem funkcije :

v2=b0+(b1+b2)*(1-exp(-v1/t))/(v1/t)-b2*exp(-v1/t)

te odabirom Gauss-Newtonove iterativne metode. Vrijednosti procijenjenih parametara nalaze se u tablici 15, u prvom stupcu (Estimate), dok se empirijske signifikantnosti parametara nalaze u četvrtom stupcu (p-level). Rezultati pokazuju da su svi parametri značajni već pri signifikantnosti od 1%, odnosno da su značajne procijenjena dugoročna i kratkoročna kamatna stopa, nagib krivulje kao i pojavljivanje udubine u vremenu τ.

Tablica 15. Procijenjeni parametri upotrebom programskog paketa Statistica

	Model is: v2=b0+(b1+b2)*(1-exp(-v1/t))/(v1/t)-b2*exp(-v1/t) Dep. Var. : Prinos do dospijeća Level of confidence: 95.0% (alpha=0.050)					
	Estimate	Standard error	t-value df = 25	p-value	Lo. Conf Limit	Up. Conf Limit
b0	0,052507	0,001032	50,87027	0,000000	0,050381	0,054632
b1	-0,027554	0,006193	-4,44952	0,000155	-0,040308	-0,014800
b2	-0,062322	0,014444	-4,31466	0,000220	-0,092070	-0,032573
t	0,182136	0,030760	5,92128	0,000004	0,118785	0,245486

Nadalje, provedeno je testiranje značajnosti modela analizom varijance (tablica 16). Promatrajući model kao cjelinu, statistički je značajan već pri signifikantnosti od 1%, što se očitava iz petog stupca (p-value). Izračunavanjem koeficijenta determinacije:

$$R^2 = \frac{SP}{ST} = \frac{0.045778}{0.045879} = 0.9978$$

zaključuje se da je 99.78% ukupnog zbroja kvadrata odstupanja stvarnih vrijednosti kamatnih stopa od procijenjenih Nelson-Siegelovim modelom protumačeno ovim modelom. Izračunat je i Spearmanov koeficijent korelacije ranga koji iznosi 0.9787 odnosno 97.87%, što upućuje na vrlo visoku korelaciju ranga stvarnih vrijednosti kamatnih stopa i vrijednosti procijenjenih Nelson-Siegelovim modelom.

Tablica 16. Testiranje značajnosti modela analizom varijance

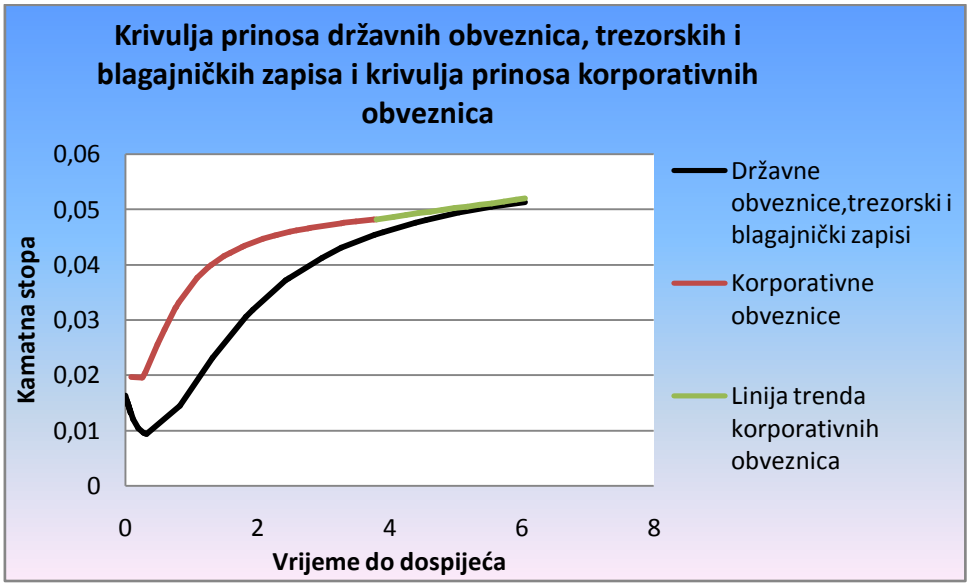
Effect	Model is: v2=b0+(b1+b2)*(1-exp(-v1/t))/(v1/t)-b2*exp(-v1/t) Dep. Var. : Prinos do dospijeća				
	1 Sum of Squares	2 DF	3 Mean Squares	4 F-value	5 p-value
Regression	0,045778	4,00000	0,011445	2842,587	0,000000
Residual	0,000101	25,00000	0,000004		
Total	0,045879	29,00000			
Corrected Total	0,002758	28,00000			
Regression vs.Corrected Total	0,045778	4,00000	0,011445	116,172	0,000000

Sva navedeno upućuje na zaključak da je procijenjeni model reprezentativan.

5.3. Usporedba krivulje prinosa za RH i krivulje prinosa korporativnih obveznica hrvatskog financijskog tržišta

Krivulja prinosa državnih obveznica, trezorskih i blagajničkih zapisa te krivulja prinosa korporativnih obveznica su prikazane na slici 19. Krivulja prinosa korporativnih obveznica je očekivano povrh krivulje prinosa državnih obveznica, trezorskih i blagajničkih zapisa. Kako su korporativne obveznice kraćeg vremena dospijeća, u svrhu reprezentativnosti, krivulja prinosa korporativnih obveznica je linijom trenda produljena do posljednjeg vremena dospijeća državnih obveznica.

Slika 19. Krivulja prinosa državnih obveznica, trezorskih i blagajničkih zapisa i krivulja prinosa korporativnih obveznica



Područje između krivulja predstavlja premiju kreditnog rizika portfelja korporativnih obveznica. Jednostavnim izračunom razlike aritmetičkih sredina obje krivulje do istog vremena dospijeća, uz pretpostavku da se portfelj sastoji od podjednakih udjela svih obveznica, dolazimo do prosječne premije kreditnog rizika[109]:

prosječni prinos korporativnih obveznica - prosječni prinos državnih obveznica =
= 0,03856 – 0,021752 = 0,016809.

Dakle, prosječna premija kreditnog rizika odabranih korporativnih obveznica iznosi 168 bps (baznih bodova) odnosno 1,68%.

Ispitat ćemo stupanj korelacije dobivene korporativne krivulje prinosa i krivulje prinosa državnih obveznica, trezorskih i blagajničkih zapisa. Iskoristit ćemo podatke o procijenjenom prinosu za približno jednaka vremena do dospijeća za obje krivulje iz kojih ćemo izračunati Spearmanov koeficijent korelacije ranga. Dobiveni rezultati su dani u tablici 17:

[109] Prosjeci su izračunati iz tablice 8 i tablice 14, uprosječivanjem trećeg stupca do vremena dospijeća od 3,80 godina.

Tablica 17. Korelacija korporativne krivulje prinosa i krivulje prinosa državnih obveznica, trezorskih i blagajničkih zapisa

Variable	Spearman Rank Order Correlations Marked correlations are significant at p <,05000	
	Var1	Var2
Var1	1,000000	0,933333
Var2	0,933333	1,000000

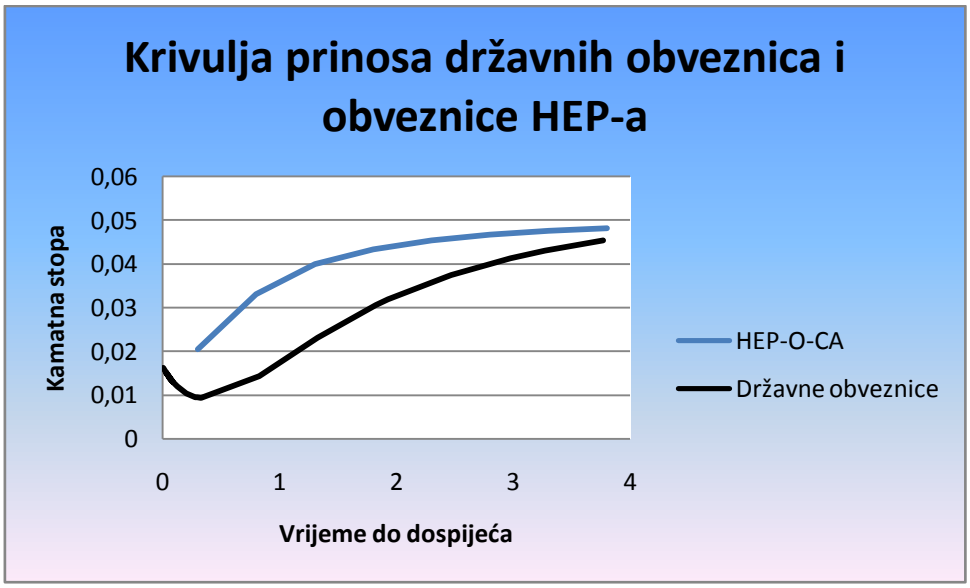
Spearmanov koeficijent korelacije ranga iznosi 0.9333 odnosno 93.33%, što upućuje na vrlo visoku korelaciju ranga prinosa obiju procijenjenih krivulja. Ovaj rezultat je snažna potpora validnosti krivulje prinosa korporativnih obveznica, jer ispunjenjem uvjeta dovoljne likvidnosti potrebnog kod uvrštavanja u portfelj korporativnih obveznica, prinosi korporativnih obveznica jako dobro koreliraju s prinosima državnih obveznica, odnosno jako dobro prate državne prinose samo na višoj razini prinosa upravo za premiju kreditnog rizika.[110]

Zbog obrnuto proporcionalnog odnosa cijene i prinosa obveznice, krivulja prinosa pojedine obveznice koja se nalazi ispod krivulje prinosa, povlači previsoku cijenu i prenisku stopu prinosa obveznice i kao takva nije atraktivna za investitore, tj. precijenjena je. Obrnuto, kada se krivulja prinosa pojedine obveznice nalazi iznad krivulje prinosa svih obveznica, njena niska cijena i visoki prinos podižu atraktivnost obveznice investitorima tj. podcijenjena je. Zbog rijetke trgovine korporativnim obveznicama ne možemo utvrditi precijenjenost ili podcijenjenost istih. Iznimka je obveznica HEP-a kojoj je procijenjen kreditni rizik od strane Standard & Poor'sa i to rangom BB[111]. Kako je kreditni rizik HEP-a jednak kreditnom riziku RH prema kriterijima iste agencije, ostavlja nam se dovoljno prostora za prikaz precijenjenosti ili podcijenjenosti dane obveznice. Još jednom smo konstruirali krivulju prinosa državnih obveznica, trezorskih i blagajničkih zapisa, a iz parova potrebnih za konstrukciju krivulje korporativnih obveznica iskoristili smo one koji se odnose na obveznicu HEP-a iz tablice 14. Slika 20 prikazuje obje krivulje iz kojih je vidljivo, da iako su istog kreditnog rizika, obveznica HEP-a nalazi se povrh krivulje prinosa državnih obveznica što

[110] Ostali testovi (Gamma i Kendall Tau) također ukazuju na vrlo visok stupanj pozitivne korelacije(>83%).
[111] *http://www.standardandpoors.com/ratings*(4.6.2014.)

implicira njenu podcijenjenost odnosno da ima prenisku cijenu i visok prinos tj. predstavlja bolju investiciju.

Slika 20. Krivulja prinosa državnih obveznica i obveznice HEP-a



5.4. Krivulje prinosa drugih zemalja i usporedba

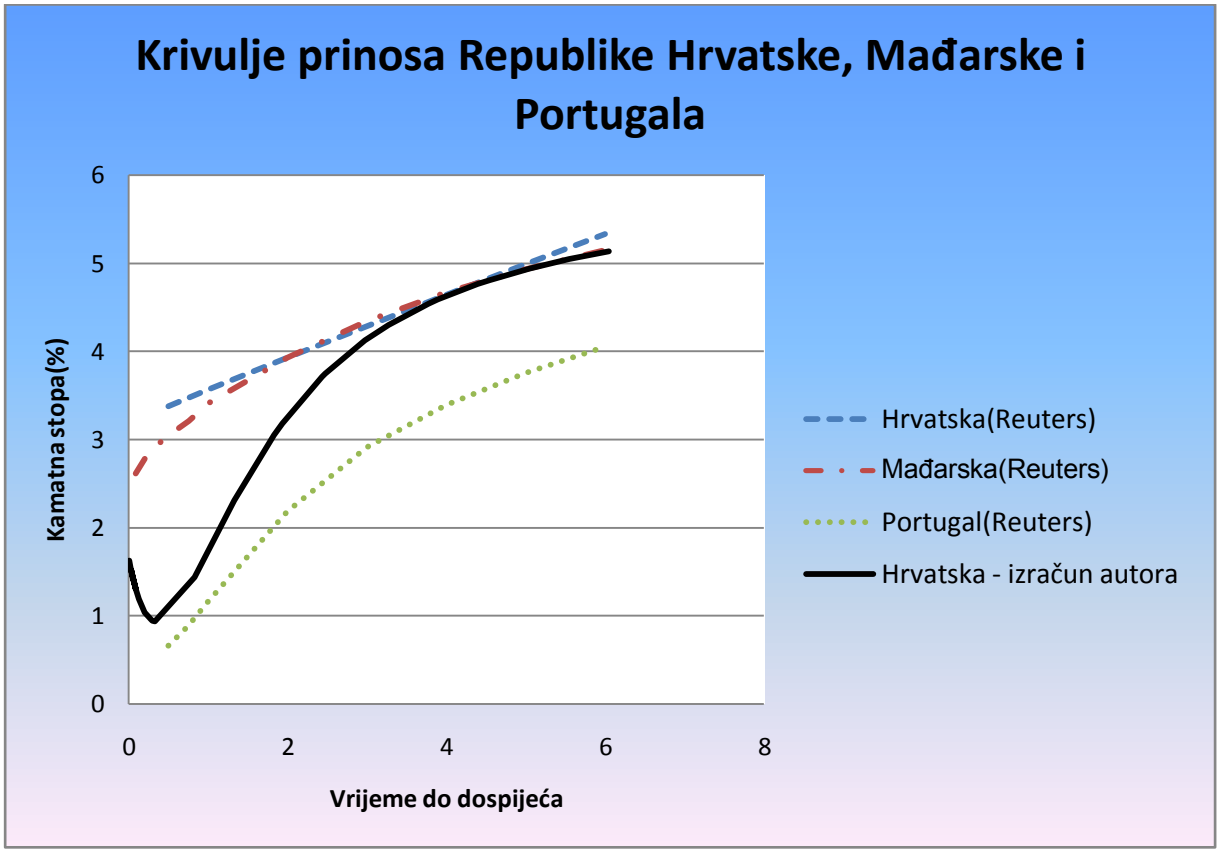
Iako nije ispravno uspoređivati krivulje prinosa različitih valuta, ipak ćemo usporedbu napraviti među zemljama Europske unije istog kreditnog rizika. Odabrane su zemlje koje prema rejting agenciji Standard&Poors imaju rang kreditnog rizika kao Republika Hrvatska, dakle BB[112]. Dovoljno podataka za usporedbu imaju samo dvije zemlje Portugal i Mađarska. Kako Reuters nudi i podatke za krivulju prinosa korporativnih obveznica navedenih zemalja izbor obje zemlje se čini kao praktičan izbor. Na slici 21, dan je pregled krivulja prinosa Portugala, Mađarske i Hrvatske kao i procijenjena krivulja od strane autora ovog rada.[113] Procijenjena krivulja prinosa i Reutersova krivulja prinosa Republike Hrvatske počevši od treće godine do dospijeća jako dobro koreliraju. Razlog značajnog raskoraka tih dviju krivulja prinosa do treće godine leži u tom što Reuters kod procjene krivulje prinosa nije ukalkulirao kratkoročne vrijednosne papire već ih nudi kao posebnu krivulju. Mađarska i hrvatska

[112] BB podrazumijeva niži srednji rang obveznica, tj. nizak stupanj špekulativnog rizika. Obveznice s BB rangiranjem i ispod toga nazivaju se“junk“ obveznice.

[113] Podaci su preuzeti iz baze Reutersa na datum 17.2.2014. (Fixed income-Bonds-Government)

krivulja prinosa prate se uz zanemariva odstupanja kroz cijelo vrijeme do dospijeća, dok se portugalska krivulja prinosa nalazi znatno ispod hrvatske krivulje prinosa, i to u rasponu kamatne stope od 2,72 do1,28 gledajući uzlazno vrijeme do dospijeća.
Bitno je istaknuti da sve krivulje prinosa imaju rastući oblik.

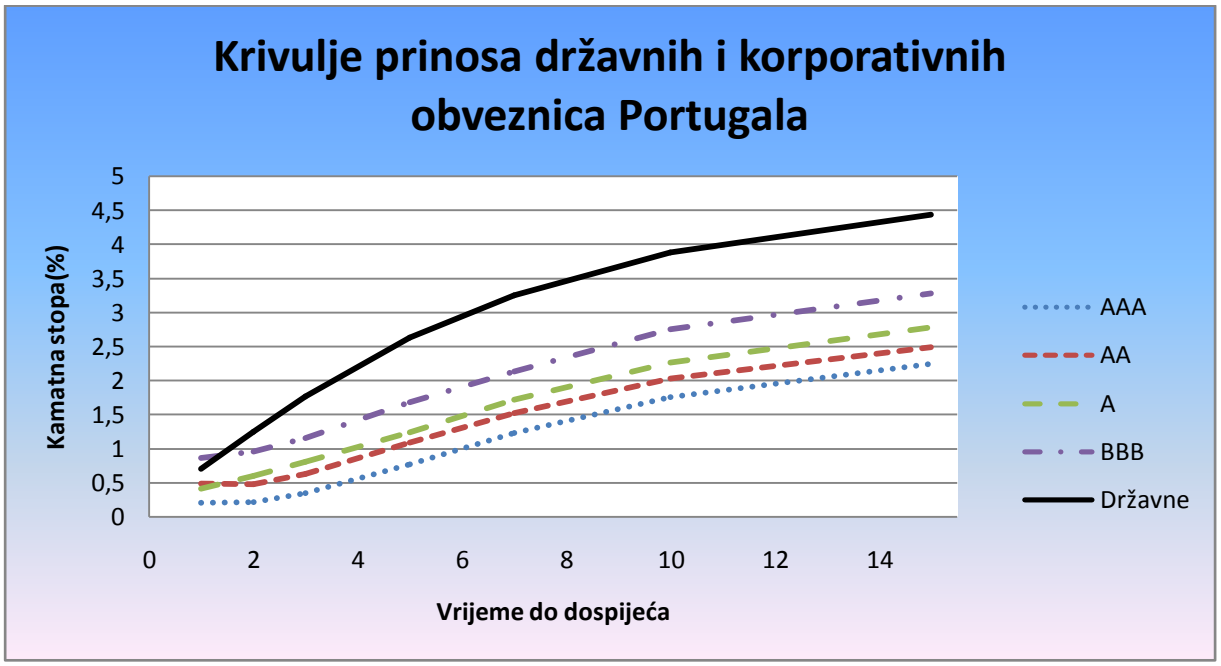
Slika 21. Krivulje prinosa Republike Hrvatske, Mađarske i Portugala



Prikaz krivulja prinosa korporativnih i državnih obveznica Portugala dan je na slici 22.[114] Korporativne obveznice se rangirane prema kreditnom riziku u razrede AAA, AA, A i BBB. Zanimljivo je da prinosi korporativnih obveznica prema kreditnom riziku odgovaraju očekivanom rasporedu krivulja, tj. viši kreditni rejting (manji kreditni rizik) znači i niži prinos obveznice. No, iako korporativne obveznice odgovaraju očekivanom redoslijedu, sve se nalaze ispod krivulje prinosa državnih obveznica, što implicira njihovu previsoku cijenu i prenizak prinos odnosno precijenjenost.

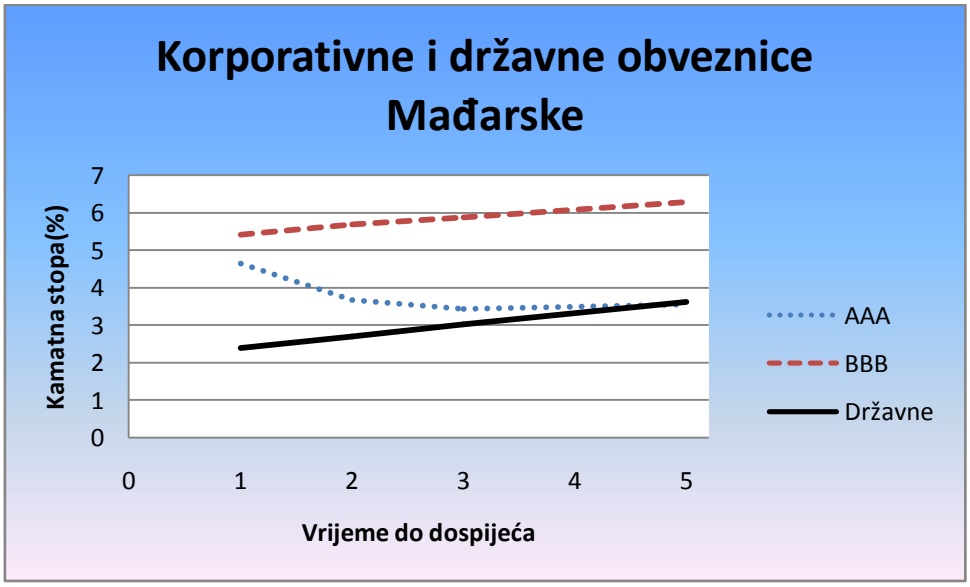
[114] Podaci su preuzeti za datum 2.6.2014. s Reutersa. Datum je promijenjen(umjesto 17.2.2014.) jer se ne mogu pronaći zbirni povijesni podaci potrebni za konstrukciju krivulje prinosa korporativnih obveznica.

Slika 22. Krivulje prinosa državnih i korporativnih obveznica Portugala



S druge strane krivulje prinosa mađarskih korporativnih obveznica nalaze se iznad krivulje prinosa njihovih državnih obveznica u očekivanom redoslijedu gledajući kreditni rejting. Korporativne obveznice su rangirane prema kreditnom riziku u razrede AAA i BBB. Prikaz krivulja prinosa korporativnih i državnih obveznica Mađarske dan je na slici 23.[115]

Slika 23. Krivulje prinosa državnih i korporativnih obveznica Mađarske



[115] Ibidem

6. ZAKLJUČAK

Krivulja prinosa od velike je važnosti u makroekonomskom i u mikroekonomskom smislu te je na razvijenim financijskim tržištima uobičajena njena procjena i objava čak na dnevnoj bazi. Razlozi zbog kojih se krivulja prinosa u Hrvatskoj ne objavljuje su nedovoljan broj izdanja državnih obveznica i trezorskih odnosno blagajničkih zapisa, kao temeljnih instrumenata u postupku procjene krivulje prinosa. Dodatnu poteškoću u Hrvatskoj predstavlja i slaba trgovina ovim vrijednosnicama na sekundarnom tržištu. Krivulja korporativnih obveznica predstavlja dodatnu ekstenziju krivulje prinosa državnih obveznica, trezorskih i blagajničkih zapisa. Njena procjena je otežana zbog još rjeđe trgovine na sekundarnim tržištima, što posljedično znači da transakcijska cijena ne može predstavljati fer cijenu korporativne obveznice. Fer cijena korporativne obveznice je nužna kod niza radnji, od revalorizacije financijske imovine nužne kod knjiženja i usklađivanja vrijednosti trgovačkog portfelja ili portfelja raspoloživog za prodaju, zatim otkrivanja onih obveznica koje su precijenjene ili podcijenjene, kao i u samoj esenciji posjedovanja validne informacije potrebne svakom investitoru.

Na temelju dobivenih i prezentiranih podataka prvu pomoćnu istraživačku hipotezu koja glasi:

- *Moguće je procijeniti krivulju prinosa državnih obveznica, trezorskih i blagajničkih zapisa na hrvatskom financijskom tržištu,*

prihvaćamo. U radu je prikazano da je procjena krivulje moguća, pod uvjetom da je na datum procjene zabilježena barem donekle zadovoljavajuća trgovina blagajničkim zapisima odnosno obveznicama, što uz podatke s tržišta novca može predstavljati zadovoljavajuću bazu ulaznih podataka. Na dostupne podatke primijenjen je Nelson-Siegelov model te je dobivena krivulja prinosa. Nelson-Siegelov model pokazao se jednostavan i nezahtjevan u primjeni te pogodan zbog prethodno navedenih nedostataka na hrvatskom financijskom tržištu.

Testiranjem svih parametara modela i izračunavanjem koeficijenta korelacije stvarnih i procjenjenih kamatnih stopa NS modelom te provjeravanjem značajnosti modela analizom varijance, drugu pomoćnu istraživačku hipotezu koja glasi:

- *Parametrijski Nelson-Siegelov model je valjan model za procjenu krivulje prinosa državnih obveznica, trezorskih i blagajničkih zapisa na hrvatskom financijskom tržištu, tj. svi parametri Nelson-Siegelova modela prilikom procjene krivulje prinosa državnih obveznica, trezorskih i blagajničkih zapisa na hrvatskom financijskom tržištu su statistički značajni,*

prihvaćamo. Svi parametri modela su značajni, koeficijent korelacije stvarnih i procijenjenih kamatnih stopa je visok i analiza varijance ukazuje na značajnost modela. Tim rezultatima je potvrđena relevantnost krivulje prinosa državnih obveznica, trezorskih i blagajničkih zapisa.

Na temelju provedenog istraživanja, matematičkih i statističkih metoda, modela za procjenu krivulje prinosa, dobivenih i prezentiranih podataka te potvrđenih pomoćnih hipoteza, glavnu istraživačku hipotezu koja glasi:

- *Moguća je procjena validne krivulje prinosa korporativnih obveznica na hrvatskom financijskom tržištu,*

prihvaćamo. Za procjenu krivulje prinosa korporativnih obveznica u portfelj su uvrštene obveznice zadovoljavajuće likvidnosti. Iako na odabrani datum nije zabilježena dovoljna trgovina uvrštenim obveznicama, uz pomoć linearne interpolacije cijene obveznica te NS modela, konstruirana je krivulja prinosa korporativnih obveznica. Svi parametri modela su značajni, koeficijent korelacije stvarnih i procijenjenih kamatnih stopa je visok i analiza varijance ukazuje na značajnost modela. Ipak, najsnažniji argument validnosti dobivene krivulje krije se u vrlo visokim koeficijentima korelacije prinosa korporativnih obveznica i državnih obveznica, trezorskih i blagajničkih zapisa. Dakle, ispunjenjem uvjeta dovoljne likvidnosti potrebnog kod uvrštavanja u portfelj korporativnih obveznica, prinosi korporativnih obveznica jako dobro koreliraju s prinosima državnih obveznica, trezorskih i blagajničkih zapisa, odnosno jako dobro ih prate samo na višoj razini kamatne stope upravo za visinu premije kreditnog rizika korporativnih obveznica.

LITERATURA

1. Aljinović, Z.: *Difuzijski modeli u analizi hrvatskog tržišta državnih vrijednosnica,* doktorska disertacija, Ekonomski fakultet u Zagrebu, 2002.
2. Aljinović, Z., Ercegovac, R., Marasović, B.: *Fair value accounting in finance industry and yield/discount curve development – case study Croatia*, Global Business & Economics Anthology, Vol. 1(2008.), pp. 76-85
3. Aljinović, Z., Marasović, B.: *Matematički modeli u analizi razvoja hrvatskog financijskog tržišta,* Ekonomski fakultet u Splitu, 2012.
4. Aljinović, Z., Marasović, B., Šego, B.: *Financijsko modeliranje*, II. Izmijenjeno i dopunjeno izdanje, Ekonomski fakultet u Splitu, 2011.
5. Aljinović, Z., Marasović, B., Škrabić, B.: *Comparative Analysis of the Stochastic and Parsimonious Interest Rates Models on Croatian Government Market*, International Journal of Business, Economics, Finance and Management Sciences, Vol. 3(2009.), pp.1-22
6. Aljinović, Z., Marasović, B., Škrabić, B.: *Interest Rates in Croatia – Term Structure and the Influence of Economic Events"*, Croatian Operational Research Society (CRORS), KOI 2008., pp. 89-100
7. Tomić-Plazibat, N., Aljinović, Z., Marasović, B.: *Matematički modeli u financijskom upravljanju*, Ekonomski fakultet u Splitu, 2006.
8. Aljinović, Z., Pivac, S., Šego, B.: *CIR model i njegova primjena na državne vrijednosnice*, Ekonomski pregled, Vol. 54(2003), No.3/4 , str. 249-287
9. Aljinović, Z.; Poklepović, T.; Katalinić, K.: *Best Fit Model for Yield Curve Estimation*,Croatian Operational Research Review (CRORR), Vol. 3(2012.), pp. 28-40
10. Allfaro, R., Becerra, J. S., Sagner, A.: *The Dynamic Nelson-Siegel model: empirical results for Chile and US*, MPRA Paper 25912, University Library of Munich, Germany, 2010.
11. Anić-Antić, P., Volarević, H., Varović, M.: *Utjecaj metoda vrednovanja ulaganja u dugotrajnu materijalnu* imovinu, Ekonomski pregled, Vol. 57(2006), No.11, str.789-808
12. Annaert, J., Claes, A. G. P., Ceuster, M. J. K., Zhang, H.: *Estimating the Yield Curve Using Nelson-Siegel Model – A Ridge Regression Approach*, Universiteit Antwerpen, Belgium, 2010.

13. Babić, Z., Aljinović, Z.: *Some improvements in calculation and use of bond duration*, Mathematical communications, Vol. 1(2001), pp. 23-32
14. Bajo, A., Ott, K., Mihaljek, D.: *Hrvatski javni dug: Upravljanje i izazovi razvoja tržišta*, Institut za javne financije, Zagreb, 2011.
15. Beninga, S.: *Financial Modeling(3rd Edition)*, The MIT Press, Cambridge, 2008.
16. Berec, R.: *Extraction of Nelson-Siegel Factors from Bond Prices*, Comenius University in Bratislava - Faculty of Mathematics, Physics and Informatics-Department of Applied Mathematics and Statistics, 2010.
17. Blanchard, O.: *Macroeconomics* (*4th Edition*), Prentice Hall Business Publishing, 2006.
18. Choudhry, M.: *Bond Market Securities*, Prentice Hall Business Publishing, 2001.
19. Christensen H. E. J. , Diebold X. F. , Rudebusch D. G. :*The affine arbitrage-free class of Nelson-Siegel term structure models*, Working Paper Series 2007-20, Federal Reserve Bank of San Francisco, 2007.
20. Dragić, K., Lamza, D.: *Determinante dizajniranja domaćeg tržišta državnih vrijednosnica*, Ekonomski pregled, Vol. 55(2004.), No.11/12, str.967-1001
21. Ercegovac, R.: *Rizik kamatnih stopa na tržištu obveznica*, Magistarski rad, Ekonomski fakultet u Splitu, 2000.
22. Ercegovac, R., Kundid, A.: *Modelski pristup fer vrijednosti korporativnih obveznica u Republici Hrvatskoj*, Računovodstvo i financije, Vol. LVI(2010.), No. 6, str.76-80
23. Estrella, A.: *Why Does the Yield Curve Predict Output and Inflation?*, Economic Journal, Vol. 115(2005.), No.505, pp. 722-744
24. Galac, T.: *Globalna kriza i kreditna euroizacija u Hrvatskoj*, Hrvatska narodna banka, Istraživanja I-33, 2011.
25. Gasha, G., He, Y., Medeiros, C., Rodriguez, M., Salvati, J., Yi, J.: *On the Estimation of Term Structure Models and An Application to the United States*, IMF Working Paper, 2010.
26. Grum, A.: *The Effect of Parallel OTC-DVP Bond Market Introduction on Yield Curve Volatility*, Zbornik radova Ekonomskog fakulteta u Rijeci, Vol. 24(2006.), No.1, str. 123-140
27. Jefferson Institute : *Tržište obveznica u Srbiji*: *Izazovi regulative za efikasno tržište*, Beograd, 2005.
28. Kolačević, S.: *Javni dug kao ključna varijabla ostvarenja ciljeva ekonomske politike*, Ekonomski pregled, Vol. 62(2011.), No. 3/4, str. 208-229

29. Korunić, T., Bjelkanović, D.: *Trebaju li Hrvatskoj primarni dileri za državne vrijednosnice?*, Intercapital Zagreb, 2011.
30. Marciniak, M.: *Yield Curve Estimation at the National Bank of Poland*, National Bank of Poland working paper N° 47, 2006.
31. Mast Henderson, T.: *Fixed Income Stategy: A practitioner's Guide to Riding the Curve*, John Wiley and Sons, 2003.
32. Miloš, D.: *Perspektive razvoja Hrvatskog tržišta korporacijskih obveznica*, Financijska teorija i praksa, Vol. 28(2004.), No. 4, str. 417-434
33. Nelson, C. R., Siegel, A. F.: *Parsimonious modeling of yield curves*, Journal of Business,Vol. 60(1987.), str. 473-89
34. Orsag, S.: *Financiranje emisijom vrijednosnih papira*, RIFIN, Zagreb, 1997.
35. Pojatina, D.: *Tržište kapitala*, Ekonomski fakultet u Splitu, 2000.
36. Prohaska, Z.: *Upravljanje vrijednosnim papirima*, Infoinvest, Zagreb, 1996.
37. Raspudić Golomejić, Z.: *Koordinacija upravljanja javnim dugom i vođenja monetarne politike u Hrvatskoj*, Financijska teorija i praksa, Vol. 31(2007.), No. 2, str.151-179
38. Rose, S. Peter: *Menadžment komercijalnih banaka*, Mate, Zagreb, 2005.
39. Sumpor, M.: *Tržište državnih vrijednosnica*, Ekonomski pregled, Vol. 53(2002.), No.3/4, str. 319-332
40. Svensson, L.E.O.: *Estimating and interpreting foward interest rates: Sweden 1992-1994*, Cambridge: National Bureau of Economic Research (Working paper, 4871)
41. Vidučić, Lj.: *Financijski menadžment*, VII. Dopunjeno i izmijenjeno izdanje, RRiF plus, Zagreb, 2011.
42. Zelenika, R.: *Metodologija i tehnologija izrade znanstvenog i stručnog djela*, 4. izdanje, Ekonomski fakultet u Rijeci, 2000.

Ostali izvori:

1. http://e-lib.efst.hr
2. http://e-lib.efst.hr/2011/2090074.pdf
3. http://e-lib.efst.hr/2012/2101815.pdf
4. http://useconomy.about.com
5. http://themarketcycle.blogspot.com
6. http://web.efzg.hr/dok

7. http://web.efzg.hr/dok//FIN/abajo//4.1.%20PRIMARNO%20TRZISTE%20JAVNOG%20DUGA%20U%20HRVATSKOJ.pdf
8. http://web.efzg.hr/dok/sta/vbahovec/statisticke%20metode%20za%20ekonomske%20analize/4_PREDAVANJE_jednostavna%20linearna%20regresija.pdf
9. http://zse.hr/
10. http://www.banka.hr/hrvatska/metronet-ne-moze-isplatiti-dospjele-kamate
11. http://www.banka.hr/hrvatska/ocekivano-nexe-grupa-ne-moze-isplatiti-kamatu-na-obveznice
12. http://www.bbs.edu.rs
13. http://www.bloomberg.com
14. http://www.business.hr/kompanije/institut-igh-sklopio-predstecajnu-nagodbu
15. http://www.ekof.bg.ac.rs
16. http://www.ericsson.com/hr/etk/novine/kom080907/22.pdf
17. http://www.hanfa.hr
18. http://www.ictbusiness.info/telekomunikacije/metronet-zavrsio-predstecajnu-nagodbu
19. http://www.investopedia.com
20. http://www.mfin.hr
21. http://www.moj-bankar.hr
22. http://www.poslovni.hr
23. http://www.poslovni.hr/mobile/burze/krediti-ce-jos-godinama-biti-popularniji-od-obveznica-199111
24. http://www.poslovnipuls.com/2014/03/27/ingra-na-korak-do-sklapanja-predstecajne-nagodbe/
25. http://www.ripe.hanfa.hr/hr/analize
26. http://www.rethinkyourdefence.com.au
27. http://www.reuters.com
28. http://www.saperinvestire.it
29. http://www.splitskabanka.hr/trzista/analize/arhiva/dnevni-financijski-servis
30. http://www.ssc.upenn.edu/~fdiebold/papers/paper49/Diebold-Li.pdf
31. http://www.tportal.hr/biznis/novaciulaganje/266237/Ingra-i-IGH-ne-mogu-platiti-kamatu-po-obveznicama.html
32. http://www.vps.ns.ac.rs/arhiva
33. https://www.wikinvest.com
34. http://www.asset-analysis.com

35. www.hnb.hr
36. www.obveznice.com
37. www.scribd.com
38. www.SEEbiz.eu
39. www.skdd.hr
40. www.trzistenovca.hr
41. Odluka o upravljanju kamatnim rizikom u knjizi banke("Narodne novine", br. 2/2010., 34/2010. i 37/2012.)

POPIS SLIKA

Slika 1. Rastući oblik krivulje prinosa
Slika 2. Ravni oblik krivulje prinosa
Slika 3. Padajući oblik krivulje prinosa
Slika 4. Grbavi oblik krivulje prinosa(s lokalnim maksimumom, izbočinom)
Slika 5. Grbavi oblik krivulje prinosa(s lokalnim minimumom, udubinom)
Slika 6. Prikaz jednogodišnje i dvogodišnje obveznice
Slika 7. Odnos između teorije preferiranja likvidnosti (preferiranog područja) i teorije očekivanja
Slika 8: Ukupno tržište duga
Slika 9. Vremenski tijek upisa jednog izdanja obveznica
Slika 10. Tržišna kapitalizacija u 2013. godini u milijunima kuna
Slika 11. Popis uvrštenih obveznica u 2013. godini
Slika 12. Popis uvrštenih komercijalnih zapisa u 2013. godini
Slika 13. Popis uvrštenih prava u 2013. godini
Slika 14. Popis uvrštenih obveznica u prvom kvartalu 2014. godine
Slika 15. Popis uvrštenih komercijalnih zapisa u prvom kvartalu 2014. godine
Slika 16. Popis uvrštenih prava u prvom kvartalu 2014. godine
Slika 17. Krivulja prinosa
Slika 18. Krivulja prinosa korporativnih obveznica
Slika 19. Krivulja prinosa državnih obveznica, trezorskih i blagajničkih zapisa i krivulja prinosa korporativnih obveznica
Slika 20. Krivulja prinosa državnih obveznica i obveznice HEP-a
Slika 21. Krivulje prinosa Republike Hrvatske, Mađarske i Portugala
Slika 22. Krivulje prinosa državnih i korporativnih obveznica Portugala
Slika 23. Krivulje prinosa državnih i korporativnih obveznica Mađarske

POPIS TABLICA

Tablica 1. Popis uvrštenih korporativnih obveznica po godinama

Tablica 2. Popis uvrštenih korporativnih obveznica u prvom kvartalu 2014.godine

Tablica 3. Trgovina blagajničkim zapisima na dan 17.2.2014.

Tablica 4. Podaci o trgovanju obveznicama

Tablica 5. Izračun cijene obveznice

Tablica 6. Prinos do dospijeća nul-kupon obveznica

Tablica 7. Izračunati prinosi do dospijeća za ostale kuponske obveznice

Tablica 8. Izračun krivulje prinosa Nelson-Siegelovim modelom

Tablica 9. Procijenjeni parametri upotrebom programskog paketa Statistica

Tablica 10. Testiranje značajnosti modela analizom varijance

Tablica 11. Podaci o odabranim korporativnim obveznicama

Tablica 12. Izračun cijene korporativne obveznice

Tablica 13. Izračunati prinosi do dospijeća za korporativne obveznice iz portfelja

Tablica 14. Izračun krivulje prinosa korporativnih obveznica Nelson-Siegelovim modelom

Tablica 15. Procijenjeni parametri upotrebom programskog paketa Statistica

Tablica 16. Testiranje značajnosti modela analizom varijance

Tablica 17. Korelacija korporativne krivulje prinosa i krivulje prinosa državnih obveznica, trezorskih i blagajničkih zapisa

Tablica 18. Izračun parametara linearne funcije kojom se interpolira potraživana cijena korporativne obveznice ATGR-O-169A

PRILOZI

Prilog 1

Programski alat Microsoft Excel pomoćnom funkcijom Add trendline nudi različite tipove interpolacije, uz prikazivanje jednadžbe (linije trenda) i prognoze unaprijed i unazad za odabrani broj vremenskih perioda. U pozadini izračuna linearne funkcije kojom se interpoliraju podaci stoji model jednostavne linearne regresije.
Modelom jednostavne linearne regresije izražena je stohastička linearna veza između zavisne varijable *y* i nezavisne varijable *x*, koja se može formalno opisati izrazom:

$$y = f(x) + \varepsilon,$$

gdje je *f(x)* linearna funkcija varijable *x*, tj. $f(x) = \alpha x + \beta$. Parametri α i β su nepoznati parametri, dok je ε slučajna varijabla koja jednadžbi daje stohastički karakter. Bez dubljeg ulaska u konstrukciju modela i njegove pretpostavke[116], parametri α i β su dani sljedećim relacijama:

$$\alpha = \frac{n\sum_{i=1}^{n} x_i y_i - \sum_{i=1}^{n} x_i \sum_{i=1}^{n} y_i}{n\sum_{i=1}^{n} x_i^2 - \left(\sum_{i=1}^{n} x_i\right)^2} \quad \text{i} \quad \beta = \frac{\sum_{i=1}^{n} y_i - \alpha \sum_{i=1}^{n} x_i}{n}.$$

Iz baze Reutersa su preuzeti povijesni podaci o trgovanju odabranih korporativnih obveznica. U tablici 18 je primjer linearne interpolacije potraživane cijene za obveznicu ATGR-O-169A modelom jednostavne linearne regresije. Kako se posljednji dostupni podaci odnose na 29. listopada 2013. godine potrebno je osim interpolacije preuzetih podataka procijeniti potraživanu cijenu za datum 17. veljače 2014. godine odnosno 111 dana nakon zadnjeg dostupnog podatka. Jednostavnim izračunom prema gornjim relacijama dobiveni su koeficijenti α i β, tj. linearna funkcija koja interpolira preuzete podatke glasi

$$f(x) = 0.011596x + 98.5269.$$

Potrebno je procijeniti cijenu za traženi datum pa ćemo za argument *x* uzeti vrijednost 679 (568 dana od prvog zabilježenog datuma plus 111 dana do traženog datuma) te procijenjena

[116] Detaljnije o modelu jednostavne linearne regresije pogledati na http://web.efzg.hr/dok/sta/vbahovec/statisticke%20metode%20za%20ekonomske%20analize/4_PREDAVANJE_jednostavna%20linearna%20regresija.pdf (12.6.2014.)

potraživana cijena iznosi 106.398. Excelova funkcija Add trendline daje gotovo identičan rezultat. Ovaj izračun se analogno provodi za sve ostale potraživane i ponuđene cijene iz portfelja korporativnih obveznica.

Tablica 18. Izračun parametara linearne funcije kojom se interpolira potraživana cijena korporativne obveznice ATGR-O-169A

ATGR 6.7500 20-Sep-2016 | Thomson Reuters Eikon								
HR / HRK						**ISSUED**		
ATLANTIC GRUPA DD						**ISIN**: HRATGRO169A0, **LOCAL CODE**: ATGR-O-169A, **WERTPAPIER**: A1GV39		
Historical Data								
Ask Price								
Frequency	Daily	**Range**	3M	**From**	10-Apr-2012	**To**	29-Oct-2013	
Statistical Summary								
	Minimum Value		**Avg Value**	**Maximum Value**		**Latest Value**		
Ask Price	98,700	10-Apr-2012	102,704	104,750	27-Aug-2013	104,750	29-Oct-2013	

Date	**Ask Price**	Broj dana počevši od prvog zabilježenog					
	Var Y	Var X	X*Y	X*X		**alfa**	0,011596
29-Oct-2013	104,75	568	59498	322624		**beta**	98,5269
28-Oct-2013	104,75	567	59393,25	321489		**Procijenjena potraživana cijena na datum 17.veljače 2014.**	106,398
25-Oct-2013	104,75	564	59079	318096			
24-Oct-2013	104,75	563	58974,25	316969			
23-Oct-2013	104,75	562	58869,5	315844			
22-Oct-2013	104,75	561	58764,75	314721			
21-Oct-2013	104,75	560	58660	313600			
18-Oct-2013	104,75	557	58345,75	310249			
17-Oct-2013	104,75	556	58241	309136			
16-Oct-2013	104,75	555	58136,25	308025			
15-Oct-2013	104,75	554	58031,5	306916			
14-Oct-2013	104,75	553	57926,75	305809			
11-Oct-2013	104,75	550	57612,5	302500			
10-Oct-2013	104,75	549	57507,75	301401			
09-Oct-2013	104,75	548	57403	300304			
07-Oct-2013	104,75	546	57193,5	298116			
04-Oct-2013	104,75	543	56879,25	294849			
03-Oct-2013	104,75	542	56774,5	293764			
02-Oct-2013	104,75	541	56669,75	292681			
01-Oct-2013	104,75	540	56565	291600			

30-Sep-2013	104,75	539	56460,25	290521
27-Sep-2013	104,75	536	56146	287296
26-Sep-2013	104,75	535	56041,25	286225
25-Sep-2013	104,75	534	55936,5	285156
24-Sep-2013	104,75	533	55831,75	284089
23-Sep-2013	104,75	532	55727	283024
20-Sep-2013	104,75	529	55412,75	279841
19-Sep-2013	104,75	528	55308	278784
18-Sep-2013	104,75	527	55203,25	277729
17-Sep-2013	104,75	526	55098,5	276676
16-Sep-2013	104,75	525	54993,75	275625
13-Sep-2013	104,75	522	54679,5	272484
12-Sep-2013	104,75	521	54574,75	271441
11-Sep-2013	104,75	520	54470	270400
10-Sep-2013	104,75	519	54365,25	269361
09-Sep-2013	104,75	518	54260,5	268324
06-Sep-2013	104,75	515	53946,25	265225
05-Sep-2013	104,75	514	53841,5	264196
04-Sep-2013	104,75	513	53736,75	263169
03-Sep-2013	104,75	512	53632	262144
02-Sep-2013	104,75	511	53527,25	261121
30-Aug-2013	104,75	508	53213	258064
29-Aug-2013	104,75	507	53108,25	257049
28-Aug-2013	104,75	506	53003,5	256036
27-Aug-2013	104,75	505	52898,75	255025
11-May-2012	98,700	32	3158,4	1024
10-May-2012	98,700	31	3059,7	961
09-May-2012	98,700	30	2961	900
08-May-2012	98,700	29	2862,3	841
07-May-2012	98,700	28	2763,6	784
04-May-2012	98,700	25	2467,5	625
03-May-2012	98,700	24	2368,8	576
02-May-2012	98,700	23	2270,1	529
30-Apr-2012	98,700	21	2072,7	441
27-Apr-2012	98,700	18	1776,6	324
26-Apr-2012	98,700	17	1677,9	289
25-Apr-2012	98,700	16	1579,2	256
24-Apr-2012	98,700	15	1480,5	225
23-Apr-2012	98,700	14	1381,8	196
20-Apr-2012	98,700	11	1085,7	121
19-Apr-2012	98,700	10	987	100
18-Apr-2012	98,700	9	888,3	81
17-Apr-2012	98,700	8	789,6	64
16-Apr-2012	98,700	7	690,9	49
13-Apr-2012	98,700	4	394,8	16
12-Apr-2012	98,700	3	296,1	9
11-Apr-2012	98,700	2	197,4	4
10-Apr-2012	98,700	1	98,7	1
Σ	6983,8	24492	2563250	12946114

Prilog 2

ŽIVOTOPIS

OSOBNI PODACI

Ime i prezime	Ante-Toni Vrdoljak
Datum i mjesto rođenja	21.09.1984., Split
Adresa	Makarska ulica 42, Split
Telefon	098 9262 761
E-mail	atvrdoljak@gmail.com ante.toni.vrdoljak@efst.hr

OBRAZOVANJE

2010. -	Poslijediplomski specijalistički studij poslovne ekonomije, Ekonomski fakultet u Splitu
2010.	Dopunsko pedagoško-psihološko obrazovanje nastavnika, Sveučilište u Zadru
2003.-2009.	PMF-Matematički odjel, dipl. inž. matematike, smjer Financijska i poslovna matematika, Sveučilište u Zagrebu
1999.-2003.	III Gimnazija (MIOC), Split

RADNO ISKUSTVO

2012.–	Vanjski suradnik asistent na matematičkoj skupini kolegija, Ekonomski fakultet u Splitu
2011. –	Vanjski suradnik na kolegiju Matematika i Statistika, Sveučilišni studijski centar za studije mora u Splitu
2010.	Učitelj matematike u OŠ Brda, Split (stalno zaposlenje)
2009.-2010.	Nastavnik i učitelj matematike na zamjeni u splitskim srednjim i osnovnim školama

VJEŠTINE

Rad na računalu	OS: Windows/Linux C, Pascal, Matlab HTML/CSS, MySQL MS Office
Strani jezici	Engleski aktivno Njemački pasivno

SAŽETAK

Vremenska struktura kamatnih stopa je pojam kojim se označava veza između stope prinosa, odnosno kamatne stope od određene vrste vrijednosnih papira i njihovog vremena dospijeća. Grafički prikaz odnosa ovih dviju varijabli naziva se krivulja prinosa. Krivulja prinosa od velike je važnosti u makroekonomskom i u mikroekonomskom smislu te je na razvijenim financijskim tržištima uobičajena njena procjena i objava čak na dnevnoj bazi. Oblik krivulje prinosa empirijski se pokazao kao značajan prediktor inflacije i realne ekonomske aktivnosti. Krivulja prinosa korporativnih obveznica predstavlja dodatnu ekstenziju krivulje prinosa državnih obveznica. Ona je potrebna kod niza radnji, od revalorizacije financijske imovine do otkrivanja onih obveznica koje su precijenjene ili podcijenjene, kao i u samoj esenciji posjedovanja validne informacije potrebne svakom investitoru.U ovom radu procijenjena je krivulja prinosa korporativnih obveznica hrvatskog financijskog tržišta na određeni datum te krivulja prinosa državnih obveznica, trezorskih i blagajničkih zapisa. Za tu svrhu upotrijebljen je Nelson-Siegelov model iz skupine parametrijskih modela za procjenu krivulje prinosa. Konačno, testiranjem parametara modela te visokim koeficijentima koreliranosti ovih dviju krivulja potvrđuje se njihova validnost.

SUMMARY

Term structure of interest rates is a term used to indicate the relationship between the rate of income, ie interest rates of certain types of securities and their time to maturity. Graphical representation of relation between these two variables is called the yield curve. Yield curve is of the great importance in the macroeconomic and microeconomic terms and in developed financial markets it is usually estimated and published even on a daily basis. The shape of the yield curve is empirically proven to be a significant predictor of inflation and real economic activity. Corporate bond yield curve represents an additional extension of the yield curve of government bonds. It is necessary in a variety of actions, from the revaluation to disclosure of those bonds that are overestimated or underestimated, as well as the very essence of possessing the valid information necessary to every investor. In this paper we estimated the yield curve of corporate bonds of the Croatian financial market on a particular date and the yield curve of government bonds and treasury bills. For this purpose, we use the Nelson-Siegel model from a group of parametric models for estimation of the yield curve. Finally, the validity of resulting yield curves is confirmed by testing the model's parameters and the high correlation coefficients between them.

Ovaj rad posvećujem svojim najdražima, supruzi Mariji i sinu Niki, čija ljubav, potpora i nježnost su mi dali snagu da ustrajem.