

PRIMJENA DONJE POLU-VARIJANCE NA REGIONALNA TRŽIŠTA KAPITALA

Škarica, Ana

Master's thesis / Diplomski rad

2017

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:124:059535>

Rights / Prava: [In copyright](#) / [Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-04-19**

Repository / Repozitorij:

[REFST - Repository of Economics faculty in Split](#)



UNIVERSITY OF SPLIT



DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJ

SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET

DIPLOMSKI RAD

**PRIMJENA DONJE POLU-VARIJANCE NA
REGIONALNA TRŽIŠTA KAPITALA**

Mentorica:

Prof. dr.sc. Zdravka Aljinović

Studentica:

Ana Škarica, univ. bacc. oec.

broj indeksa: 2151081

Split, studeni 2017.

Zahvaljujem se svojoj mentorici, prof.dr.sc. Zdravki Aljinović na vodstvu, stručnim savjetima i pomoći prilikom izrade diplomskog rada.

Želim se zahvaliti i svim prijateljima koji su mi svojim prisustvom uljepšali vrijeme provedeno na fakultetu i bez kojih cijeli tijek studiranja ne bi prošao tako lako i zabavno.

Posebnu zahvalnost želim iskazati svojoj obitelji koja mi je uvijek pružala podršku i upućivala me na pravi put.

SADRŽAJ

1. UVOD	5
1.1. Problem istraživanja.....	5
1.2. Predmet istraživanja	7
1.3. Svrha i ciljevi istraživanja.....	8
1.4. Istraživačke hipoteze.....	8
1.5. Metode istraživanja	8
1.6. Struktura istraživanja	9
1.7. Doprinos istraživanja	10
2. MV MODEL OPTIMIZACIJE PORTFELJA I PRIKAZ DONJE POLU-VARIJANCE KAO MJERE RIZIKA.....	11
2.1. Teorijske postavke MV modela	11
2.2. Prinos portfelja	12
2.3. Očekivana vrijednost prinosa portfelja	13
2.4. Varijanca prinosa portfelja.....	14
2.5. Funkcija korisnosti	16
2.6. Efikasna granica	17
2.7. Doprinosi i kritike Markowitzevog modela.....	20
2.8. Izbor optimalnog portfelja alternativnim mjerama rizika.....	22
2.9. Model optimizacije portfelja s donjom polu-varijancom kao mjerom rizika	24
3. STATISTIČKA ANALIZA STANJA NA REGIONALNIM TRŽIŠTIMA KAPITALA I ISPITIVANJE NORMALNOSTI TRŽIŠTA	27
3.1. Temeljne odrednice regionalnih tržišta kapitala	27
3.2. Ispitivanje distribucije prinosa na hrvatskom tržištu kapitala	30
3.3. Ispitivanje distribucije prinosa na slovenskom tržištu kapitala	33
3.4. Ispitivanje distribucije prinosa na srbijanskom tržištu kapitala.....	36
4. FORMIRANJE EFIKASNIH GRANICA PRIMJENOM MV MODELA	38

4.1.Procjena efikasne granice na hrvatskom tržištu kapitala	38
4.2.Procjena efikasne granice na slovenskom tržištu kapitala.....	41
4.3.Procjena efikasne granice na srbijanskom tržištu kapitala	43
4.4.Usporedba efikasnih granica na hrvatskom, slovenskom i srbijanskom tržištu dobivenih primjenom MV modela	45
5. FORMIRANJE EFIKASNIH GRANICA DONJOM POLU-VARIJANCOM	46
5.1.Procjena efikasne granice na hrvatskom tržištu kapitala donjom polu- varijancom kao mjerom rizika.....	46
5.2.Procjena efikasne granice na slovenskom tržištu kapitala donjom polu- varijancom kao mjerom rizika.....	48
5.3.Procjena efikasne granice na srbijanskom tržištu kapitala donjom polu- varijancom kao mjerom rizika.....	50
5.4.Usporedba efikasnih granica na hrvatskom, slovenskom i srbijanskom tržištu kapitala izračunatih primjenom donje polu-varijance kao mjere rizika.....	53
5.5.Usporedba efikasnih granica dobivenih varijancom kao mjerom rizika i donjom polu-varijancom kao mjerom rizika	54
6. ZAKLJUČAK	56
LITERATURA	59
PRILOZI.....	61
POPIS SLIKA	79
POPIS TABLICA.....	80
SAŽETAK.....	81
SUMMARY	81

1. UVOD

1.1. Problem istraživanja

U vremenu sve većeg razvoja tržišta kapitala i volatilnosti prinosa na vrijednosnice, izazov za svakog investitora je pronaći optimalan portfelj. Trend razvoja matematičkih i statističkih metoda, kao i računalnih programa u investicijskom menadžmentu uvjetuje konstanto učenje i primjenu novih spoznaja. Brojni autori istraživali su problem pronalaženja optimalnog portfelja.

Temeljni model moderne teorije portfelja postavio je Harry M. Markowitz u svom radu „Portfolio Theory“ 1952. godine. Dotadašnji pristup optimizacije portfelja temeljio se na maksimizaciji očekivanog prinosa, što je vodilo vrlo rizičnom ulaganju ukupnih novčanih sredstava u dionicu s najvećim očekivanim prinosom. Cilj modernog Markowitzevog upravljanja portfeljem je optimizacija odnosa očekivanog prinosa i pripadajućeg mu rizika.¹ Ovaj pristup optimizaciji portfelja u skladu je s maksimom „*Nije dobro držati sva jaja u jednoj košari*“. Mnogi investitori su se uvjerali u istinitost ove tvrdnje, ali tek Markowitz razvija prvi matematički model koji će pokazati kako odabrati košare, to jest vrijednosnice.²

Osnovna Markowitzeva ideja bila je naći ravnotežu između rizika (tj. varijance prinosa portfelja) i prihoda (tj. očekivane vrijednosti prinosa portfelja), te izabrati portfelj dionica koji donosi najveću moguću dobit uz najmanji mogući rizik. Takav portfelj koji za zadanu stopu rizika ima najveću stopu prihoda, odnosno portfelj koji za zadanu stopu prihoda ima minimalan rizik, Markowitz je nazvao efikasnim portfeljem. Koristeći se Markowitzevim modelom, ulagač iz skupa svih mogućih portfelja odabire onaj portfelj (efikasni portfelj) čiji odnos očekivanog prihoda i očekivanog rizika odgovara njegovoj sklonosti ili averziji prema riziku.³

Markowitzev model optimizacije portfelja poznat je i kao MV model (mean-variance model) kojem je H. Markowitz udario temelje modernoj teoriji portfelja. O važnosti MV modela svjedoči

¹ Tomić-Plazibat, N., Aljinović, Z., Marasović, B., (2006): Matematički modeli u financijskom upravljanju, Split:Sveučilište u Splitu, Ekonomski fakultet Split, str. 1.

² Marasović, B., (2006): Modeli optimizacije investicijskog portfelja, magistarski rad, Sveučilište u Zagrebu, Ekonomski fakultet, Split, str. 5.

³ Aljinović, Z., Marasović, B., Šego, B., (2011): Financijsko modeliranje, II. izmijenjeno i dopunjeno izdanje, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 137.-138.

i činjenica da je Harry Markowitz za svoja dostignuća 1990. godine nagrađen Nobelovom nagradom za ekonomiju, te njegova primjena od strane financijskih institucija i stručnjaka koji se susreću sa problemima financijskog modeliranja.⁴ Međutim, veća primjena Markowitzevog modela ukazala je na određene nedostatke koji se temelje na neispunjenju pretpostavki tog modela.

Naime, Markowitzev pristup optimizaciji portfelja zahtjeva neke stroge pretpostavke kao što je normalna distribucija prinosa. Ipak, istraživanja provedena na različitim tržištima kapitala pokazala su da pretpostavka o normalnoj distribuciji prinosa često nije zadovoljena u praksi.⁵ Podaci s različitih tržišta kapitala pokazali su da je najučestaliji asimetričan oblik distribucije prinosa dionica s debelim repovima.⁶ To znači da su ekstremni događaji (vrlo veliki dobici ili vrlo veliki gubici) mnogo vjerojatniji u usporedbi s normalnom distribucijom. Drugo nezgodno svojstvo varijance je njena simetričnost. Kada se govori o riziku, misli se na rizik od gubitka iako varijanca mjeri i „rizik“ od dobitka. Dionice čiji prinosi ispod očekivane vrijednosti više variraju u odnosu na očekivanu vrijednost su rizičnije vrijednosnice. Prethodno upućuje na zaključak da varijanca općenito nije adekvatna mjera rizika.⁷

Slijedom navedenog, razvijene su donje parcijalne mjere rizika koje mjere odstupanje samo onih prinosa koji su manji od očekivanog prinosa ili nekog ciljanog prinosa, a u koje se ubrajaju:⁸

- Donja polu-varijanca (donja polu-standardna devijacija)
- Donja polu-apsolutna devijacija
- Podciljni rizik
- Rizičnost vrijednosti (Value at Risk – VaR)
- Uvjetna rizičnost vrijednosti (Conditional Value at Risk – CVaR)

⁴ Tomić-Plazibat, N., Aljinović, Z., Marasović, B., (2006): Matematički modeli u financijskom upravljanju, Split:Sveučilište u Splitu, Ekonomski fakultet Split, str. 2.

⁵ Marasović, B., (2006): Modeli optimizacije investicijskog portfelja, magistarski rad, Sveučilište u Zagrebu, Ekonomski fakultet, Split, str. 30.

⁶ Marasović, B., (2016): Model za rebalans portfelja s uključenim transakcijskim troškovima i donjom poluapsolutnom devijacijom kao mjerom rizika, Ekonomska misao i praksa, No2, str. 515.-534.

⁷ Marasović, B., (2006): Modeli optimizacije investicijskog portfelja, magistarski rad, Sveučilište u Zagrebu, Ekonomski fakultet, Split, str. 34.

⁸ Aljinović, Z., (2016): Od varijance prema alternativnim mjerama rizika u Modernoj portfolio teoriji (MPT), nastavni materijali, Ekonomski fakultet, Beograd

Očekivani ili ciljani prinos odražava perspektive rizika od investitora do investitora. Ako pretpostavimo da je investitor zabrinut samo zbog gubitka početnog uloga, ciljani prinos će biti jednak nula, a vjerojatnost gubitka glavnice će biti promatrana kao rizična. U slučajevima kad je očekivani prinos investitora 10%, bilo koji povrat ispod tog praga će se smatrati rizičnim. U skladu s tim, polu-varijanca se definira kao ponderirana suma kvadrata odstupanja prinosa od očekivanog prinosa, uzimajući u obzir samo vrijednosti ispod očekivanog prinosa. Markowitz također uočava nedostatke varijance, te 1959. godine u svojoj knjizi „*Portfolio Selection: Efficient Diversification of Investments*“ predstavlja polu-varijancu kao mjeru rizika.⁹

Moderna teorija portfelja uspješno se primjenjuje na razvijena tržišta kapitala koje karakterizira velik broj dionica i visok stupanj likvidnosti. S druge strane, došlo je do pojave novih tržišta kapitala, tzv. tržišta u nastajanju (*emerging markets*).¹⁰ Zajedničke odlike takvih tržišta obuhvaćaju plitkost i nelikvidnost tržišta, nedostatak tržišta transparentnosti, visoke transakcijske troškove, nekompatibilnost računovodstvenih standarda s međunarodnim standardima i slabo korporativno upravljanje.¹¹ U tržišta kapitala u nastajanju ubrajaju se i regionalna tržišta kapitala, kao što su hrvatsko, slovensko i srbijansko tržište. Specifičnosti tržišta u nastajanju, analizirane u okviru regionalnih tržišta kapitala, predstavljaju polazište za istraživanje nedostataka i mogućnosti poboljšanja primjene Markowitzove teorije portfelja. Dodatno, značaj proučavanja primjene Markowitzove teorije portfelja na regionalna tržišta kapitala proizlazi iz potencijalne diversifikacije portfelja zbog manjeg stupnja korelacije s razvijenim tržištima kapitala, te privlačnosti regionalnih tržišta zbog većih prinosa u skladu s višim rizicima.

1.2. Predmet istraživanja

Predmet istraživanja ovog rada je primjena modela donje polu-varijance na regionalna tržišta kapitala. Kao reprezentativni primjer regionalnih tržišta kapitala razmatrat će se i empirijski

⁹ Boasson, V., Boasson, E., Zhou, Z., (2011): Portfolio optimization in a mean-semivariance framework, Investment Management and Financial Innovations, Volume 8, Issue 3, 58.- 68.

¹⁰ Latković, M., Barac, Z., (1999): Optimizacija dioničkih portfelja na rubnim tržištima kapitala, preprint, Sveučilište u Zagrebu, Zagreb

¹¹ Stanivuk, T., (2009): Mogućnosti i ograničenja primjene Markowitzove teorije portfelja na hrvatskom tržištu kapitala, magistarski rad, Sveučilište u Splitu, Ekonomski fakultet, Split

analizirati stanje na hrvatskom, slovenskom i srbijanskom tržištu kapitala. S obzirom da navedena tržišta kapitala predstavljaju tržišta u nastajanju ili izranjajuća tržišta primjenjivost MV modela može biti upitna. U skladu s tim, istražiti će se pretpostavka o normalnoj distribuciji prinosa na tržištima, te formirati efikasne granice primjenom donje polu-varijance. U svrhu istraživanja koristit će se podaci o cijenama najlikvidnijih dionica koje kotiraju na Zagrebačkoj, Ljubljanskoj i Beogradskoj burzi.

1.3. Svrha i ciljevi istraživanja

Cilj istraživanja je definirati i prikazati osnovne odrednice MV modela s varijancom kao mjerom rizika, te donjom polu-varijancom kao mogućom alternativnom mjerom rizika. Posebno će se istaknuti kritike i nedostaci primjene Markowitzeve teorije portfelja u kontekstu karakteristika plitkih, nelikvidnih tržišta.

U radu će se testirati primjena donje polu-varijance kao mjere rizika na hrvatskom, slovenskom i srbijanskom tržištu kapitala, te će se istražiti može li se ovaj model koristiti prilikom donošenja odluke o formiranju efikasnog portfelja na navedenim tržištima kapitala.

1.4. Istraživačke hipoteze

Na temelju definiranog problema, predmeta i ciljeva istraživanja postavlja se radna istraživačka hipoteza:

- S obzirom na karakteristike regionalnih tržišta kapitala donja polu-varijanica prikladnija je mjera rizika od varijance

Pomoćna hipoteza:

- Prinosi dionica na regionalnim tržištima kapitala nisu normalno distribuirani

1.5. Metode istraživanja

U svrhu istraživanja i oblikovanja rada koristit će se različite znanstvene metode primjenjive u društvenim znanostima. Rad je podijeljen na teorijski i empirijski dio o čemu će ovisiti izbor korištenja metoda.

U teorijskom dijelu rada koristit će se metoda indukcije, jer će se od nekih pojedinačnih pojava dolaziti do općih zaključaka. Također, deduktivnom metodom, od nekih općenitih sudova doći će se do pojedinačnih. U teorijskom dijelu koristit će se i metoda deskripcije kojom će se opisivati i objašnjavati teorijske odrednice Markowitzevog modela optimizacije portfelja. Metodom analize, specifičnosti regionalnih tržišta kapitala raščlanjivat će se na jednostavnije sastavne dijelove koji će se dalje analizirati, dok će se metodom sinteze pojedini elementi spajati u cjelinu. U radu će se koristiti i metoda kompilacije jer će se izložiti tuđi stavovi i zaključci iz domaće i strane literature.

S ciljem prihvaćanja ili odbacivanja hipoteze, u empirijskom dijelu rada koristit će se matematičke i statističke metode i modeli. Podaci potrebni za izračun bit će prikupljeni sa internetskih stranica Zagrebačke, Ljubljanske i Beogradske burze. Za potrebe izračuna statističkih modela koristit će se IBM SPSS Statistics, a za potrebe izračuna matematičkih vrijednosti koristit će se MS Excel Premium Solver. Rezultati izračuna prikazat će se tablično i grafički.

1.6. Struktura istraživanja

Diplomski rad će se sastojati od šest glavnih poglavlja uključujući uvod i zaključak.

Prvo poglavlje je *Uvod* u kojem će se definirati problem i predmet istraživanja, postaviti istraživačke hipoteze, navesti metode korištene u radu, te doprinos istraživanja. Na kraju uvodnog dijela prikazat će se sadržaj i struktura diplomskog rada.

U drugom poglavlju detaljno će se prikazati osnovne teorijske odrednice MV modela, kao i nedostaci njegove primjene koji uvjetuju upotrebu alternativnih mjera rizika, te će se pobliže upoznati sa donjom polu-varijancom kao mjerom rizika.

Treće poglavlje obuhvaća prikaz karakteristika regionalnih tržišta kapitala, te statističku analizu stanja na hrvatskom, slovenskom i srbijanskom tržištu kapitala i ispitivanje normalnosti prinosa na navedenim tržištima.

Izračun i grafički prikaz efikasnih portfelja na regionalnim tržištima kapitala primjenom Markowitzevog modela bit će izložen u četvrtom poglavlju.

Zatim slijedi peto poglavlje u kojem se izračunavaju i formiraju efikasne granice primjenom donje polu-varijance na odabranim tržištima kapitala.

U posljednjem poglavlju, odnosno u *Zaključku*, izložit će se rezultati istraživanja na temelju kojih će se prihvatiti ili odbaciti postavljena hipoteza.

Na samom kraju rada bit će prikaz korištene literature, prilozi, popis tablica, grafova i slika, te sažetak na hrvatskom i sažetak na engleskom jeziku.

1.7. Doprinos istraživanja

Doprinos ovog rada je izložiti postojeću literaturu vezanu za model optimizacije portfelja s donjom polu-varijancom kao mjerom rizika te istražiti primjenu takvog modela na regionalna tržišta kapitala. Moderna teorija portfelja predmet je proučavanja brojnih autora, ali njena široka primjena nije bila moguća sve do razvoja računalnih programa. Stoga, doprinos ovog rada će se ogledati i u obogaćivanju literature iz ovog područja. Rad može poslužiti studentima i svima zainteresiranim za financijsko modeliranje u razumijevanju problematike pronalaženja optimalnog portfelja na regionalnim tržištima kapitala.

2. MV MODEL OPTIMIZACIJE PORTFELJA I PRIKAZ DONJE POLU-VARIJANCE KAO MJERE RIZIKA

2.1. Teorijske postavke MV modela¹²

Prvi ozbiljan pokušaj da se tržište opiše konzistentnim matematičkim modelom datira iz 1952. godine kada je nobelovac H. M. Markowitz postavio temelje moderne teorije portfelja uvodeći model za izbor optimalnog portfelja u uvjetima neizvjesnosti i rizika. 1959. godine Markowitz u objavljuje knjigu *Portfolio Selection: Efficient Diversification of Investments* u kojoj razvija teoriju prema kojoj se rizik i nagrada (prihod) mogu uravnotežiti u dobro odabranoj kombinaciji vrijednosnica, tj. portfelju. Naime, cilj modernog upravljanja portfeljem nije maksimizacija očekivanog prihoda nego optimiranje odnosa očekivanog prihoda i pripadajućeg rizika.

Osnovna Markowitzeva zamisao je bila naći ravnotežu između rizika i prinosa, te izabrati portfelj dionica koji donosi najveću moguću dobit uz najmanji mogući rizik. Kao što je poznato, preuzimanjem većeg rizika moguće je ostvariti i veći profit. Markowitzev model, poznat kao i MV model (*mean-variance model*) polazi od pretpostavke da investitori imaju averziju prema riziku i kao takvi žele maksimizirati svoju korisnost, tj. dobit. Dakle, Markowitzeva ideja je bila formiranje matematičkog modela za izbor portfelja koji donosi najveću stopu prihoda, ali na određenom stupnju rizika. Portfelj koji za zadanu stopu rizika ima najveću stopu prihoda, odnosno portfelj koji za zadanu stopu prihoda ima minimalan rizik, Markowitz je nazvao *efikasnim portfeljem*.

Koristeći se Markowitzevim modelom, investor iz skupa svih mogućih portfelja odabire onaj portfelj (efikasni portfelj) čiji odnos očekivanog prihoda i očekivanog rizika odgovara njegovoj osobnoj ulagačkoj filozofiji.

Dobiveni „jaki“ rezultati ovog modela posljedica su pretpostavki da je funkcija korisnosti investitora kvadratna funkcija U oblika, te da su prinosi vrijednosnih papira normalno distribuirani.¹³

¹² Napisano prema: Aljinović, Z., Marasović, B., Šego, B., (2011): Financijsko modeliranje, II. Izmijenjeno i dopunjeno izdanje, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 136-138.

2.2. Prinos portfelja¹⁴

Pretpostavka od koje se polazi je da investitor može ulagati u n različitih vrijednosnih papira u trenutku $t=0$ i da ih posjeduje sve do trenutka $t=T^4$. Nadalje pretpostavljamo da nema transakcijskih troškova i da su vrijednosnice savršeno djeljive. U praksi je pretpostavka o beskonačnoj djeljivosti puno bolje aproksimirana kod velikih portfelja institucionalnih investitora kao što su fondovi i sl. nego kod malih portfelja pojedinačnih ulagača.

Ako u trenutku $t \in \{0, T\}$ cijena vrijednosnog papira $P_i(0)$, odnosno $P_i(T)$, tada se složeni kontinuirani prinos pojedinog vrijednosnog papira računa izrazom:

$$R_i = \ln \left(\frac{P_i(T)}{P_i(0)} \right) \quad (1)$$

a diskretni prinos izrazom:

$$R_i = \frac{[P_i(T) - P_i(0)]}{P_i(0)} \quad (2)$$

Ako je u promatranom vremenskom razdoblju isplaćena dividenda za promatranu dionicu, tada se ukupni prinos dionice računa tako da se brojnicima gornjih izraza doda isplaćena dividenda. Prinos izračunat kontinuiranim ukamaćivanjem uvijek je manji od prinosa izračunatog diskretnim ukamaćivanjem, ali razlika najčešće nije velika. U slučaju kada se na osnovu prinosa iz prošlosti određuje distribucija prinosa, čija očekivana vrijednost predstavlja očekivanu vrijednost prinosa za sljedeće razdoblje, prikladnije je računanje prinosa kontinuiranim ukamaćivanjem.

Nadalje, s π_i označavamo dio početnog uloga x investiranog u vrijednosnicu i u trenutku $t=0$, to jest:

$$\pi_i = \frac{\psi_i P_i(0)}{x} \quad (3)$$

¹³ Tomić-Plazibat, N., Aljinović, Z., Marasović, B., (2006): Matematički modeli u financijskom upravljanju, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 2.

¹⁴ Napisano prema: Tomić-Plazibat, N., Aljinović, Z., Marasović, B., (2006): Matematički modeli u financijskom upravljanju, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 2.-6.

gdje je ψ_i broj i -tih vrijednosnica kupljenih u trenutku $t=0$. Vektor $\pi = (\pi_1, \dots, \pi_n)'$ označava vektor portfelja investitora. Nadalje vrijedi:

$$\sum_{i=1}^n \pi_i = 1 \quad (4)$$

Ukupni prinos ili prinos portfelja u trenutku $t=T$ ovisit će o izboru vektora portfelja π na početku promatranog razdoblja:

$$R^\pi = \frac{X^\pi(T) - x}{x} \quad (5)$$

gdje su

$$X^\pi(T) = \sum_{i=1}^n \psi_i P_i(T) \quad (6)$$

ukupna novčana sredstva dobivena prodajom dionica u trenutku $t=T$

U diskretnom slučaju vrijedi:

$$R^\pi = \sum_{i=1}^n \pi_i R_i \quad (7)$$

Ponekad udjeli π_i , $i \in \{1, 2, \dots, n\}$ mogu poprimiti i negativne vrijednosti, što je u praksi poznato pod pojmom kratke prodaje (short sale). Kratka prodaja je jedna od vrsta trgovine na financijskim tržištima. Kod kratke prodaje investitor prvo prodaje vrijednosnicu koja nije u njegovom fizičkom vlasništvu, to jest posudi vrijednosnicu od treće osobe (npr. brokera) i proda je, nadajući se kasnijoj kupnji po nižoj cijeni.

2.3. Očekivana vrijednost prinosa portfelja¹⁵

¹⁵ Napisano prema: Tomić-Plazibat, N., Aljinović, Z., Marasović, B., (2006): Matematički modeli u financijskom upravljanju, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 7.

Cijena vrijednosnice $P_i(t)$ u nekom budućem trenutku t je slučajna varijabla, tako je i prinos te iste vrijednosnice u trenutku t , $R_i(t)$, slučajna varijabla.

Vrijednosti prinosa iz nekih razdoblja iz prošlosti imaju određenu distribuciju. Markowitz u svom modelu pretpostavlja da su distribucije prinosa portfelja i distribucije prinosa individualnih ulaganja približno normalnog oblika. Normalna distribucija je određena s aritmetičkom sredinom i standardnom devijacijom. Problem se svodi na pronalaženje povezanosti aritmetičke sredine i standardne devijacije prinosa portfelja s odgovarajućim parametrima distribucije prinosa pojedinačnih vrijednosnih papira koji čine portfelj.

Uvažavajući da je očekivana vrijednost zbroja slučajnih varijabli jednaka zbroju očekivanih vrijednosti, to jest da vrijedi $E(X+Y) = E(X)+E(Y)$ i da je očekivana vrijednost umnoška konstante i slučajne varijable jednaka umnošku konstante i očekivane vrijednosti slučajne varijable, to jest da vrijedi $E(\alpha X) = \alpha E(X)$ iz navedenog slijedi izraz za očekivani prinos portfelja:

$$\mu_\pi = E(R_\pi) = E\left(\sum_{i=1}^n \pi_i R_i\right) = \sum_{i=1}^n \pi_i E(R_i) = \sum_{i=1}^n \pi_i \mu_i \quad (8)$$

Dakle, aritmetička sredina ili očekivana vrijednost prinosa portfelja koji se sastoji od n vrijednosnica je vagana aritmetička sredina prinosa individualnih ulaganja, gdje su ponderi udjeli pojedinih vrijednosnica u portfelju definirani relacijom (3).

2.4. Varijanca prinosa portfelja¹⁶

Rizik ulaganja u pojedinu vrijednosnicu Markowitz kvantificira varijancom prinosa $Var(R_i)$. S obzirom na prethodno spomenutu pretpostavku modela o normalnoj distribuciji prinosa, dionice čija vrijednost više varira u odnosu na očekivanu vrijednost su rizičnije vrijednosnice, stoga varijanca predstavlja prikladnu mjeru rizika. U slučajevima kada je varijanca prinosa jednaka nuli, možemo reći da je vrijednosnica bezrizična (risk-free asset), u protivnom slučaju vrijednosnica sadrži rizik.

¹⁶ Napisano prema : Tomić-Plazibat, N., Aljinović, Z., Marasović, B., (2006): Matematički modeli u financijskom upravljanju, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 8.-9.

Rizik portfelja predstavlja varijancu prinosa portfelja definiranu izrazom:

$$Var(R^\pi) = E\left\{[R^\pi - E(R^\pi)]^2\right\} \quad (9)$$

Korištenjem linearnosti matematičkog očekivanja, može se pokazati da je:

$$Var(R^\pi) = E[(R^\pi)^2] - [E(R^\pi)]^2 \quad (10)$$

Raščlanjivanjem gornjeg izraza te primjenom svojstava aditivnosti i multiplikativnosti očekivane vrijednosti slučajne varijable, dobiva se:

$$Var(R^\pi) = \sum_{i=1}^n \sum_{j=1}^n \pi_i \sigma_{ij} \pi_j \quad (11)$$

$$\sigma_{ij} = Cov(R_i, R_j) = E(R_i R_j) - E(R_i)E(R_j), \quad i, j \in \{1, 2, \dots, n\} \quad (12)$$

Kovarijanca prinosa vrijednosnice same sa sobom σ_{ii} , $i \in \{1, 2, \dots, n\}$ može se tretirati kao varijanca prinosa promatrane vrijednosnice:

$$Var(R_i) = E[(R_i)^2] - [E(R_i)]^2 = E(R_i R_i) - E(R_i)E(R_i) = Cov(R_i, R_i) \quad (13)$$

Budući da je:

$$\sum_{i=1}^n \sum_{j=1}^n \pi_i \pi_j = 1 \quad (14)$$

Možemo reći da jednakost (11) izražava $Var(R^\pi)$ kao vagani prosjek n^2 varijanci i kovarijanci prinosa vrijednosnica u portfelju.

Za razliku od očekivane vrijednosti prinosa portfelja koja je linearna funkcija udjela investicija u portfelju, varijanca prinosa portfelja nije linearna funkcija udjela investicija. Razlog tome je što se moguće varijance prinosa oko očekivane vrijednosti svake investicije ne moraju poklapati niti intenzitetom niti smjerom kretanja. Stoga varijanca prinosa portfelja ovisi o sljedećim parametrima: udjelima pojedinih vrijednosnica u portfelju, njihovim varijancama prinosa i korelacijama između prinosa tih vrijednosnica u portfelju.

2.5. Funkcija korisnosti¹⁷

Prilikom izbora vrijednosnica u portfelj, investitor će uvijek uzeti u obzir korisnost (očekivani prinos) koji ima od pojedine vrijednosnice. Upravo je fizičar Daniel Bernoulli ukazao na uvažavanje elemenata rizika u izboru između odgovarajućih akcija, sugerirajući maksimizaciju očekivane korisnosti kao relevantan kriterij prilikom izbora u situacijama rizika.

Funkcija korisnosti $U(W)$ je rastućeg oblika, što znači da investitor uvijek preferira mogućnost koja ima veći prinos u usporedbi s mogućnošću koja ima manji prinos, uz pretpostavku da su obje mogućnosti jednako vjerojatne.

Oblik funkcije korisnosti ovisit će o ulagačevom stavu prema riziku. Osobe koje izbjegavaju rizik (risk-averse person) neće investirati u slučaju kada vjerojatnost dobitka veličine G iznosi 50% i vjerojatnost gubitka veličine G iznosi 50% što možemo zapisati kao:

$$U(W) - U(W-G) > U(W+G) - U(W) \quad (15)$$

Ovakva funkcija korisnosti konkavnog je oblika što znači da investitor koji izbjegava rizik smanjuje novčani udio svoje imovine investirane u rizični portfelj usporedno s povećanjem svojeg bogatstva.

U slučajevima kad je osoba indiferentna prema riziku (risk-neutral person) funkcija korisnosti je linearna, s obzirom da je investitoru svejedno hoće li investirati dio bogatstva u slučaju kad je vjerojatnost dobitka G 50%, a isto tako vjerojatnost gubitka G 50%. Za takvog investitora vrijedi:

$$U(W) - U(W-G) = U(W+G) - U(W) \quad (16)$$


Za osobe sklone riziku (risk-seeking person) vrijedit će jednadžba:

$$U(W) - U(W-G) < U(W+G) - U(W) \quad (17)$$

A funkcija korisnosti koja zadovoljava gornju jednadžbu je konveksnog oblika.

¹⁷ Napisano prema : Tomić-Plazibat, N., Aljinović, Z., Marasović, B., (2006): Matematički modeli u financijskom upravljanju, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 9.-12.

Sva tri oblika funkcije korisnosti u zavisnosti o ulagačevom stavu prema riziku prikazana su na donjem grafikonu.



Slika 1: Funkcija korisnosti investitora koji izbjegava rizik, investitora koji je indiferentan u odnosu na rizik i investitora koji je sklon riziku

Izvor: Tomić-Plazibat, N., Aljinović, Z., Marasović, B., (2006): Matematički modeli u finansijskom upravljanju, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 12.

Funkcija korisnosti investitora koji ulaže na tržište kapitala može se prikazati kao funkcija očekivanog prinosa portfelja. Očekivana vrijednost funkcije korisnosti tada ovisi o očekivanom prinosu portfelja i varijanci:

$$E(U) = E(U)(\mu_{\pi}, \sigma_{\pi}^2) \quad (18)$$

Prethodna jednakost od velike je važnosti za teoriju portfelja, jer je očekivani prinos i varijancu mnogo lakše kvantificirati nego očekivanu korisnost. Markowitz u svom radu pretpostavlja da je funkcija korisnosti konkavna, odnosno da postoji određeni stupanj averzije prema riziku i da je kvadratna funkcija.

2.6. Efikasna granica

Očekivani prinosi svih vrijednosnica, koje smo prethodno izračunali, te varijance i kovarijance prinosa vrijednosnica, predstavljaju ulazne podatke za Markowitzev model. Prilikom oblikovanja

optimalnog portfelja, prema Markowitzevom modelu optimizacije, svaki ulagač može izabrati jedan od dva pristupa postizanja što je moguće većeg prinosa. Kod prvog pristupa ulagač zada donju granicu prinosa portfelja, i tada se iz skupa mogućih portfelja izabere onaj koji ima minimalnu varijancu, tj. minimalan rizik. Kod drugog pristupa ulagač zada gornju granicu prihvatljivog rizika i onda se iz mogućeg skupa portfelja izabere onaj koji maksimizira prinos. Matematički ova dva pristupa se mogu zapisati na sljedeći način:


$$\begin{array}{ll} \underset{\pi \in R^n}{\text{Min}} \text{Var}(R^\pi) & \underset{\pi \in R^n}{\text{Max}} E(R^\pi) \\ (I) \ E(R^\pi) \geq c_1 & (II) \ \text{Var}(R^\pi) \leq c_2 \end{array} \quad (19)$$

$$\sum_{i=1}^n \pi_i = 1 \quad \sum_{i=1}^n \pi_i = 1$$

Nepoznate varijable u ovom modelu su udjeli pojedinih dionica u portfelju π_i , $i \in \{1, 2, \dots, n\}$ odnosno vektor portfelja π kojem su π_i komponente. Glavno pitanje investitora je koliki mora biti udio svake pojedine dionice u portfelju, da bi rizik portfelja bio minimalan uz prinos ne manji od onog kojeg je ulagač unaprijed zadao (konstanta c_1), odnosno koliki mora biti udio svake pojedine dionice u portfelju da bi prinos portfelja bio maksimalan, uz rizik ne veći od onog kojeg je ulagač unaprijed zadao (konstanta c_2).¹⁸

Skup svih mogućih portfelja čine portfelji koji se mogu sastaviti od N zadanih rizičnih vrijednosnica. Budući da je svaki portfelj po Markowitzu okarakteriziran očekivanim prinosom i varijancom prinosa, možemo ga prikazati u $\sigma_\pi - E(R_\pi)$ koordinatnom sustavu. Prikažemo li sve moguće portfelje točkama u $\sigma_\pi - E(R_\pi)$ koordinatnom sustavu, dobit ćemo skup kao na slici:

¹⁸ Napisano prema : Tomić-Plazibat, N., Aljinović, Z., Marasović, B., (2006): Matematički modeli u financijskom upravljanju, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 13.-14.




Slika 2: Skup mogućih portfelja

Izvor: Aljinović, Z., Marasović, B., Šego, B., (2011): Financijsko modeliranje, II. izmijenjeno i dopunjeno izdanje, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 139.

Lijeva granica skupa mogućih portfelja se naziva skup minimalne varijance (*minimum-variance set*) kojeg sačinjavaju točke koje za danu stopu prinosa imaju najmanju varijancu.

Dio skupa minimalne varijance koji prikazuje portfelje koji za zadanu standardnu devijaciju imaju maksimalan prinos naziva se *efikasnom granicom* (*efficient frontier*).



Slika 3: (a) Skup minimalne varijance, (b) Efikasna granica

Izvor: Aljinović, Z., (2016): Od varijance prema alternativnim mjerama rizika u Modernoj portfolio teoriji (MPT), nastavni materijali, Ekonomski fakultet, Beograd

Investitora će najviše zanimati baš oni portfelji koji leže na krivulji minimalne varijance. To su oni portfelji koji za dani prinos imaju najmanju varijancu. Ukoliko ti portfelji za ujedno za zadanu stopu rizika imaju maksimalan prinos, onda oni leže na efikasnoj granici i nazivamo ih *efikasnim portfeljima*.¹⁹


2.7. Doprinosi i kritike Markowitzevog modela²⁰

Markowitzev model smatra se najznačajnijom inovacijom 20. stoljeća na području investiranja i upravljanja portfeljem vrijednosnica. Markowitzev model prezentiran u njegovom doktoratu, predstavlja početak rađanja ekonomije tržišta kapitala. Sve do 1952. godine, nije postojao model koji će pokazati kako odabrati dionice koje sačinjavaju portfelj, tj. smatralo se da svaku dionicu treba odabrati putem fundamentalne analize i u portfelj uvrstiti one koji posjeduju potencijal rasta. Nadalje, Markowitz je ukazao na važnost međusobne koreliranosti vrijednosnica kao i na njihovu brojnost u portfelju čijim se povećavanjem smanjuje rizik (diversifikacija rizika).

Budući da je na razvijenim tržištima kapitala teško pronaći dionice sa korelacijom nula, što znači da je nemoguće u potpunosti eliminirati rizik dodavanjem sve većeg broja dionica. Ta činjenica može se povezati sa analizom ukupnog rizika koja se sastoji od dvije komponente. Prva komponenta je sustavni rizik, odnosno opći rizik na tržištu koji proizlazi iz promjena u svjetskoj i nacionalnoj ekonomiji, poreznoj politici i sl., a koji se ne može ukloniti boljom diversifikacijom portfelja. Drugi, nesustavni rizik koji se može otkloniti diversifikacijom portfelja uzrokovan je promjenama uspješnosti poslovanja pojedinog poduzeća, emitenata dionica.

¹⁹Aljinović, Z., Marasović, B., Šego, B., (2011): Financijsko modeliranje, II. izmijenjeno i dopunjeno izdanje, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 139.-140.

²⁰ Napisano prema: Marasović, B., (2006): Modeli optimizacije investicijskog portfelja, magistarski rad, Sveučilište u Zagrebu, Ekonomski fakultet, Split, str. 25.-29.



Slika 4: Ukupni, sustavni i nesustavni rizik

Izvor: Aljinović, Z., (2016): Od varijance prema alternativnim mjerama rizika u Modernoj portfolio teoriji (MPT), nastavni materijali, Ekonomski fakultet, Beograd

Kritike Markowitzevog modela proizlaze iz pretpostavke o normalnoj distribuciji prinosa. Veliki broj empirijskih testova na tržištima kapitala imali su za rezultat asimetričnu ili šiljastu distribuciju. U slučaju kada prinosi imaju normalnu distribuciju, varijanca (standardna devijacija) je prihvatljiva mjera rizika te možemo govoriti o pouzdanim i reprezentativnim rezultatima modela. U svim ostalim slučajevima potrebno je primijeniti alternativne mjere rizika. Drugi razlog kritike je u obujmu i složenosti velikog broja parametara zbog čega je MV model u vrijeme nastanka rijetko primjenjivan u praksi. Međutim, u novije vrijeme zahvaljujući razvoju računala i specijaliziranih softvera izračun optimalnog portfelja MV modelom je postao jednostavan. Također, dolazi do razvoja novih matematičkih modela optimizacije portfelja, ali

Markowitzev model i dalje ostaje bazični model optimizacije portfelja i većina novih modela se temelji upravo na njemu.

2.8. Izbor optimalnog portfelja alternativnim mjerama rizika²¹

Prethodno smo ustvrdili da Markowitzev pristup optimizaciji portfelja zahtjeva ispunjenje određenih pretpostavki kao što je normalna distribucija prinosa. Prednosti normalne distribucije su u tome što je moguće definirati samo sa dva parametra: varijancom i očekivanom vrijednosti. Međutim, podaci sa različitih tržišta kapitala pokazali su da je najčešći asimetričan oblik distribucije prinosa dionica s debelim repovima. Pri takvim distribucijama, varijanca nije adekvatna mjera rizika, stoga se uvode alternativne mjere rizika.

Iako je varijanca kao mjera rizika jednostavna za izračun, ona ne opisuje na prikladan način rizik događaja male vjerojatnosti. Statističkim testovima normalnosti distribucije može se ustvrditi da distribucije prinosa dionica često imaju debele repove. To znači da su ekstremni događaji (vrlo veliki dobici ili vrlo veliki gubici) mnogo vjerojatniji u usporedbi s normalnom distribucijom. Iako pri izračunu varijance računamo kvadrate odstupanja prinosa od aritmetičke sredine i na taj način uzimamo u obzir i velike gubitke, ipak je potrebno naći neku drugu mjeru rizika, koja će više vrednovati utjecaj pojave ekstremnih događaja.

Drugo nezgodno svojstvo varijance je njena simetričnost. Kada govorimo o riziku, prvenstveno mislimo na rizik od gubitka. Ipak varijanca mjeri i „rizik“ od dobitka, što nas u ovom slučaju ne zanima. Dionice čiji prinosi ispod očekivane vrijednosti više variraju u odnosu na očekivanu vrijednost su rizičnije vrijednosnice.

Navedena svojstva varijance upućuju na zaključak da varijanca općenito nije adekvatna mjera rizika. Iznimka su slučajevi kada je varijabilnost prinosa manjih i većih od očekivane vrijednosti jednaka, odnosno u situacijama kada prinosi imaju simetričnu distribuciju. Međutim kod asimetričnih distribucija prinosa, varijabilnost prinosa ispod i iznad očekivane vrijednosti nije jednaka. U takvim slučajevima rizik mjeren varijancom će biti precijenjen ili podcijenjen ovisno

²¹ Napisano prema: Marasović, B., (2006): Modeli optimizacije investicijskog portfelja, magistarski rad, Sveučilište u Zagrebu, Ekonomski fakultet, Split, str. 30.-34.

o tome radi li se o desnostranoj ili ljevostranoj distribuciji. Kod desnostranih distribucija, varijabilnost prinosa ispod očekivane vrijednosti je manja nego varijabilnost prinosa iznad očekivane vrijednosti. Suprotno, ako prinosi dionica imaju ljevostranu distribuciju, tada će varijabilnost prinosa ispod očekivane vrijednosti biti veća nego varijabilnost prinosa iznad očekivane vrijednosti.




Fig. 1. Right-sided distribution




Fig. 2. Left-sided distribution

Slika 5: Primjer desnostrane i ljevostrane distribucije

Izvor: Aljinović, Z., Marasović, B., Vidović, J., (2010): The alternative risk measures in Excel, Proceedings of the 33rd International Convention, MIPRO, Opatija, Croatia, str. 908.-913.

Pearsonov koeficijent asimetrije i mjera zaobljenosti sugeriraju nam ima li određena distribucija normalan oblik. Pearsonov koeficijent asimetrije podrazumijeva nagnutost distribucije na lijevu ili desnu stranu, a njegova uobičajena vrijednost se kreće u intervalu od $[-2, 2]$. Ako je vrijednost koeficijenta jednaka nuli distribucija je simetrična, kod vrijednosti koeficijenta manjoj od nule distribucija je ljevostrana, a ako je vrijednost koeficijenta veća od nule radi se o desnostranoj distribuciji. Kod izrazito asimetričnih distribucija ovaj koeficijent može poprimiti vrijednost izvan navedenog intervala. Mjera zaobljenosti predstavlja zaobljenost vrha krivulje distribucije frekvencija. Ako je vrijednost pokazatelja zaobljenosti jednaka nula riječ je o normalno

zaobljenoj distribuciji, vrijednost pokazatelja veća od nule ukazuje na šiljastiji vrh distribucije u odnosu na normalnu, dok vrijednost pokazatelja manja od nule ukazuje na tupi oblik distribucije.²²

Izbor optimalnog portfelja danas predstavlja bitnu komponentu financijskog menadžmenta. Posljednjih desetljeća, zajedno s razvojem računalne tehnologije, ubrzano se razvijaju i različiti kvantitativni modeli za rješavanje problema optimizacije portfelja, stoga je implementacija Markowitzevog i njemu srodnih modela postala znatno dostupnija.²³ S obzirom na asimetričnost distribucije prinosa, nužno je definirati alternativne mjere rizika koje uzimaju u obzir odstupanja samo onih prinosa koji su manji od očekivanog prinosa ili nekog ciljanog prinosa. Općenito, takve mjere rizika nazivamo donjim parcijalnim mjerama rizika. U donje parcijalne mjere rizika ubrajamo:²⁴

- Donja polu-varijanca (donja polu-standardna devijacija)
- Donja polu-apsolutna devijacija
- Podciljni rizik
- Rizičnost vrijednosti (Value at Risk- VaR)
- Uvjetna rizičnost vrijednost (Conditional Value at Risk - CVaR)

2.9. Model optimizacije portfelja s donjom polu-varijancom kao mjerom rizika²⁵

Varijanca je simetrična mjera disperzije koja na jednak način vrednuje dobitke i gubitke, stoga u slučajevima kada je distribucija prinosa nesimetrična, varijanca nije zadovoljavajuća mjera.

²² Pivac, S., (2010): Statističke metode, Ekonomski fakultet, Split, str. 59.-61.

²³ Marasović, B., Šego, B., (2006): Izbor optimalnog portfelja alternativnim mjerama rizika, Računovodstvo i financije, 52(2006), 7, str. 66.-71.

²⁴ Konno, H., Waki, H., Yukki, A., (2002): Portfolio Optimization Under Lower Partial Risk Measures, Asia- Pacific Financial Markets, Volume 9, Issue 2, str. 127.-140.

²⁵ Napisano prema: Marasović, B., (2006): Modeli optimizacije investicijskog portfelja, magistarski rad, Sveučilište u Zagrebu, Ekonomski fakultet, Split, str. 37.-45.

Mjera rizika koja zadržava dobra svojstva varijance i nadmašuje njene nedostatke je donja polu-varijanca.²⁶

Donja polu-varijanca je najpoznatija donja parcijalna mjera rizika. Za portfelj π donja polu-varijanca definira se izrazom:

$$V_{-}(\pi) = E\left[\left|R(\pi) - E(R^{\pi})\right|_{-}^2\right] \quad (20)$$

gdje je $R(\pi)$ stopa prinosa portfelja π i

$$|u|_{-} = \max\{0, -u\} \quad (21)$$

Donja polu-standardna devijacija $\sigma_{-}(\pi)$ definira se kao drugi korijen iz donje polu-varijance $V_{-}(\pi)$.

Pretpostavimo da je $R=(R_1, R_2, \dots, R_n)$ distribuiran na konačnom skupu točaka $r_t=(r_{1,t}, r_{2,t}, \dots, r_{n,t})$, $t \in \{1, 2, \dots, T\}$. Ove točke su dobivene izravno iz povijesnih podataka ili simulacijom. Nadalje, neka je p_t , $t \in \{1, 2, \dots, T\}$, vjerojatnost da R poprimi vrijednost $r_t=(r_{1,t}, r_{2,t}, \dots, r_{n,t})$ (obično se uzima $p_t = \frac{1}{T}$) i neka je

$$W = \left\{ (\pi_1, \pi_2, \dots, \pi_n) \left| \sum_{j=1}^n E(R_j) \pi_j \geq \rho, \sum_{j=1}^n \pi_j = 1, l \leq \pi_j \leq u, j = 1, 2, \dots, n \right. \right\} \quad (22)$$

skup mogućih portfelja, a ρ , l i u odgovarajuće konstante.

Sada je donja polu-varijanca dana izrazom:

²⁶ Aljinović, Z., Marasović, B., Pivac, S., (2007): Transition Capital Markets Comparison by Efficient Frontiers, Seventh International Conference on „Enterprise in Transition“, Faculty of Economics, Split, Split-Bol, Croatia, str. 939.-948.

$$V_{-}(\pi)E\left[\left|R(\pi)-E(R(\pi))\right|_{-}^2\right]=\left(\sum_{t=1}^T p_t\left|\sum_{j=1}^n\left(r_{j,t}-E(R_j)\right)\pi_j\right|_{-}^2\right) \quad (23)$$

Model optimizacije portfelja s donjom polu-varijancom kao mjerom rizika možemo pisati u obliku:

$$\min \sum_{i=1}^T p_t\left|\sum_{i=1}^n\left(r_{j,t}-E(R_j)\right)\pi_j\right|_{-}^2 \quad (24)$$

uz uvjet $(\pi_1, \pi_2, \dots, \pi_n) \in W$

Sada se rješenje prethodnog modela svodi na rješavanje problema kvadratnog programiranja:

$$\min \left(\sum_{t=1}^T p_t Z_t^2\right) \quad (25)$$

uz ograničenja:

$$\begin{aligned} z_t &\geq -\sum_{j=1}^n (r_{j,t} - E(R_j))\pi_j, t = 1, 2, \dots, T \\ z_t &\geq 0, t = 1, 2, \dots, T \\ \sum_{j=1}^n \pi_j &= 1 \\ \sum_{j=1}^n E(R_j)\pi_j &\geq \rho \\ \pi_j &\geq 0, j = 1, 2, \dots, n \end{aligned} \quad (26)$$

3. STATISTIČKA ANALIZA STANJA NA REGIONALNIM TRŽIŠTIMA KAPITALA I ISPITIVANJE NORMALNOSTI TRŽIŠTA


3.1. Temeljne odrednice regionalnih tržišta kapitala

Markowitzev model razvijen je i testiran na zrelim, izrazito likvidnim tržištima kapitala na kojima se trguje velikim brojem različitih vrsta finansijskih instrumenata. Ipak, interes investitora izašao je van okvira razvijenih tržišta kapitala i sve veća pažnja se posvećuje tržištima kapitala u nastajanju, čiji je udio u svjetskom tržištu kapitala sve veći.

Potencijal ovih tržišta kao investicijske alternative privukao je pažnju globalnih portfelj menadžera i finansijskih ekonomista koji naglašavaju značaj međunarodne diversifikacije i niže korelacije s razvijenim tržištima kapitala koja tržišta u nastajanju imaju. Kao odliku tržišta u nastajanju, a u koja ubrajamo i regionalna tržišta kapitala, prvenstveno treba spomenuti činjenicu da vrijednosnice tih tržišta, pored prilike za ostvarenje visokih prinosa u sebi kriju i veliki rizik. Također, treba spomenuti i druge odlike tržišta u nastajanju, a koje utječu na uspješnu primjenjivost MV modela: skromna tradicija emitiranja vrijednosnica, plitko, nelikvidno tržište i problem nesinkronog trgovanja (nema registrirane cijene), nedostatak tržišne transparentnosti, visoki transakcijski troškovi, problemi u punoj primjeni međunarodnih računovodstvenih standarda i slabo korporativno upravljanje. Visoka volatilnost izranjajućih tržišta i niska korelacija sa zrelim tržištima kapitala dovode do pomicanja efikasne granice što je ilustrirano slikom 6 na kojoj su prikazane efikasne granice dobivene kombiniranjem različite finansijske aktive i investicijskih strategija. Pored toga, prilikom međunarodne diversifikacije investitori moraju uzeti u razmatranje i rizik promjene deviznog tečaja. Svaka nagla deprecijacija nacionalne valute zemlje sa tržištem u nastajanju, drastično povećava izloženost valutnom riziku ukupnog portfelja.²⁷ Promatrajući karakteristike tržišta u nastajanju u kontekstu optimizacije portfelja treba spomenuti i utjecaj smanjene likvidnosti dionica na povećanje vjerojatnosti špekulativnog trgovanja i pojavu ekstremnih prinosa što uzrokuje brojne teškoće u ocjenama ulaznih parametara

²⁷ Mirjanić, B., (2015): Upravljanje performansama akcijskog portfolia u specifičnim uslovima novonastajućih finansijskih tržišta: Primjer Beogradske burze, doktorska disertacija, Fakultet za poslovno industrijski menadžment, Beograd

za optimizaciju. Poseban problem prilikom optimizacije je i uporaba prosječne vrijednosti povijesnih prinosa kao mjere za očekivane prinose. Takva mjera ne preporuča se niti na razvijenim tržištima kapitala, kada se izvodi optimizacija dioničkih portfelja. Razlog tome je činjenica da prosječna vrijednost povijesnih prinosa ima veliku pogrešku ocjene.²⁸



Slika 6: Efikasna granica različitih kombinacija financijske aktive i investicijskih strategija

Izvor: Mirjanić, B., (2015): Upravljanje performansama akcijskog portfolia u specifičnim uslovima novonastajućih finansijskih tržišta: Primjer Beogradske burze, doktorska disertacija, Fakultet za poslovno industrijski menadžment, Beograd

Tržišta kapitala u središnjoj i istočnoj Europi nisu postojala u vrijeme socijalizma, osim neslužbenih (sivih) tržišta, a poslije pada socijalizma tokom tranzicije doživjela su veliku ekspanziju i rast cijena vrijednosnica.²⁹ U radu će biti analizirana regionalna tržišta u nastajanju koje karakterizira gospodarska i finansijska povezanost s Europskom unijom i sličan razvojni put tranzicijskih zemalja i izazovi uspostavljanja efikasnog tržišta kapitala. Unatoč pozitivnim pomacima na regionalnim tržištima kapitala, prepreka daljnjem razvoju je još uvijek relativno visoka nelikvidnost tržišta. Ona se očituje u nedostatku stabilnih i visokih dnevnih prometa,

²⁸ Latković, M., Barac, Z., (1999): Optimizacija dioničkih portfelja na rubnim tržištima kapitala, preprint, Sveučilište u Zagrebu, Zagreb

²⁹ Prokopijević, N., (2006): Tržište kapitala u Srbiji, Bilten Beogradske burze, god. 11, br. 123/2006, str. 6.-9.

visokoj volatilnosti cijena dionica, postojanju brojnih izrazito nelikvidnih dionica te mogućnosti utjecaja na cijenu pri velikim transakcijama.³⁰

Kada govorimo o hrvatskom tržištu kapitala, tradicija emitiranja vrijednosnica radi formiranja kapitala je skromna, a dugi niz godina bankarsko-kreditno zaduživanje predstavlja najvažniji izvor eksternoga financiranja umjesto prikupljanja dioničarskoga kapitala izdavanjem dionica. Nerazvijenost financijskoga tržišta kapitala za državu znači i odricanje od mogućnosti dolaska do jeftinoga kapitala i stalno povećanje vanjske zaduženosti uz povećanje budžetskoga deficita, što je hrvatski slučaj. Također, mali broj društava ima neproporcionalno velik udio u tržišnoj kapitalizaciji i opsegu trgovine, što smanjuje likvidnost i povećava oscilacije na hrvatskom tržištu vrijednosnica. Očekuje se da će se povećanjem imovine pod upravljanjem mirovinskih investicijskih fondova i daljnjim razvojem investicijskih fondova povećati ukupna likvidnost i opseg trgovanja dionicama uvrštenih u kotacije burzi.³¹ Treba spomenuti i to da CROBEX, dionički indeks Zagrebačke burze, nije referentna vrijednost na hrvatskom tržištu kapitala, za razliku od primjerice, S&P indeksa na američkom tržištu kapitala čije se promjene prate iz minute u minutu. U proteklih pet godina hrvatsko je tržište kapitala zabilježilo znatan napredak gledano prema ostvarenom porastu prometa, tržišne kapitalizacije, broja uvrštenih vrijednosnih papira, broja dana trgovanja i sl. Ali to je još uvijek jako daleko od razine razvijenih tržišta kapitala, naročito od visokih standarda koje je postavilo američko tržište kapitala kao najrazvijenije tržište kapitala u svijetu.³² Konačno, Zagrebačka burza se posljednjih godina istakla kao pokretač konsolidacijskih procesa u regiji te je u 2016. godinu ušla kao vlasnik Ljubljanske burze nakon akvizicije koja je zaključena na samom kraju 2015. godine.³³

Slovenija, kao i Hrvatska ima bankocentrični financijski sustav. Slovensko tržište kapitala je slabo razvijeno u usporedbi s razvijenim zemljama, dok je domaći bankarski sustav relativno dobro razvijen, stoga je slovenski financijski sustav izrazito neuravnotežen. Slovensko tržište kapitala osnovano je kao rezultat distribucijske privatizacije 1990-ih godina i dugo vremena je služio za tajnu konsolidaciju vlasništva između velikih slovenskih vlasnika- privatnih i državnih,

³⁰ BeniĆ, V., Franić, I., (2008): Komparativna analiza likvidnosti tržišta kapitala Hrvatske i zemalja regije, Financijska teorija i praksa, Vol. 32, No. 4, str.481.-502.

³¹ Stanivuk, T., (2009): Mogućnosti i ograničenja primjene Markowitzve teorije portfelja na hrvatskom tržištu kapitala, magistarski rad, Sveučilište u Splitu, Ekonomski fakultet, Split

³² Jakšić, S., (2007):Primjena Markowitzve teorije na tržište dionica Zagrebačke burze, Zbornik Ekonomskog fakulteta u Zagrebu, Vol. 5, No. 1, str. 331.-334.

³³ Zagrebačka burza (2017): Pregled trgovine u 2016. godini, Zagrebačka burza d.d., Zagreb

često uz kršenje pravila transparentnosti i zakonodavstva na štetu malih dioničara. Slovenske tvrtke dodatno se financiraju prvenstveno preko banaka. Izdavanje dodatnih dionica bi ugrozilo odnos velikih vlasnika, kao i transparentnost poslovanja za vanjske investitore što često nije u interesu uprava i velikih vlasnika. Stoga, tržište kapitala nikad nije obavljalo svoju osnovnu funkciju dodatnog financiranja poduzeća izdavanjem novih dionica i obveznica na primarnom tržištu, a likvidnost tržišta nikad nije bila u skladu sa međunarodnim standardima.³⁴

Karakteristike srbijanskog tržišta kapitala svojstvene su perifernim, zaostalim tržištima. Visok rizik i niska likvidnost financijskih instrumenata nadovezuje se na tranzicijski karakter Beogradske burze gdje se i danas uglavnom nalaze dionice iz procesa privatizacije.³⁵ Broj dionica različitih poduzeća kojima se dnevno trguje je mali, oko 50. Od toga, dvadesetak dionica je na tzv. kontinuiranom trgovanju. To su „blue chip“ dionice srbijanskog tržišta. Također, jedan od većih problema je postojanje malog broja vrsta vrijednosnih papira za trgovanje. Pored dionica poduzeća, trguje se obveznicama „stare devizne štednje“ i obveznicama središnje banke. Prvi vlasnici dionica su uglavnom fizičke osobe i država (uključujući institucije), a prvi kupci su investitori i fondovi. Mali broj fizičkih osoba sudjeluje u kupovini dionica.³⁶ Kako bi se situacija na srbijanskom tržištu kapitala popravila, potrebno je još dosta rada na stvaranju kredibilnog institucionalnog okruženja i vladavine prava, ali i oporavka realnog sektora gospodarstva, bez čega nema daljnjeg razvoja financijskog tržišta i povjerenja (domaćih i stranih) investitora.³⁷

3.2. Ispitivanje distribucije prinosa na hrvatskom tržištu kapitala

Pomoćna hipoteza koja pretpostavlja da prinosi dionica na regionalnim tržištima kapitala nisu normalno distribuirani ispitat će se pomoću programa IBM SPSS Statistic. Analiza hrvatskog tržišta kapitala vršit će se na dionicama koje su uvrštene u indeks CROBEX na Zagrebačkoj burzi. U izračun će se uzeti tjedne cijene zatvaranja od 1. siječnja 2016. godine do 30. lipnja 2017. godine.

³⁴ Simoneti, M., (2010): Razvojne prilike trga kapitala v Sloveniji po finančni krizi, Institute for Economic Research, Ljubljana

³⁵ Kapor, P., (2012): Tržište kapitala u Srbiji, Megatrend Review, Vol. 9, No. 4, str. 47.-68.

³⁶ Prokopijević, N., (2006): Tržište kapitala u Srbiji, Bilten Beogradske burze, god. 11, br. 123/2006, str. 6.-9.

³⁷ Kapor, P., (2012): Tržište kapitala u Srbiji, Megatrend Review, Vol. 9, No. 4, str. 47.-68.

Uvrštene dionice, prikazane u tablici 1, zadovoljavaju kriterij od 80% dana trgovanja, određene free float kapitalizacije, te kriterij likvidnosti. Deset odabranih dionica pripadaju velikim i stabilnim poduzećima iz različitih sektora hrvatskog gospodarstva.

Tablica 1: Odabrane dionice sa Zagrebačke burze

SIMBOL DIONICE	IZDAVATELJ DIONICE
ADPL	AD Plastik d.d.
ADRS2	Adris Grupa d.d.
ATGR	Atlantic Grupa d.d.
ATPL	Atlantska plovidba d.d.
ERNT	Ericsson Nikola Tesla d.d.
HT	HT d.d.
KOEI	Končar-Elektroindustrija d.d.
PODR	Podravka d.d.
RIVP	Valamar Riviera d.d.
ZABA	Zagrebačka banka d.d.

Izvor: Izrada autorice

Na temelju tjednih cijena odabranih dionica u Excelu su izračunati prinosi svake dionice za promatrano razdoblje.

Izračunati podaci tjednih prinosa dionica na hrvatskom tržištu kapitala uspoređujemo mjerama deskriptivne statistike čime dobivamo detaljniji uvid u svojstva promatranih prinosa. U tablici 2 prikazani su statistički podaci o prinosima na hrvatskom tržištu kapitala. Najveći prosječan prinos u promatranom razdoblju ima poduzeće Atlantska plovidba, dok se dionice Podravke i Atlantic Grupe jedine ističu s negativnim prosječnim prinosom. Isto tako, dionica Atlantske plovidbe ima najveći rizik mjeren varijancom. Mjera asimetrije (skewness) i mjera zaobljenosti (kurtosis) sugeriraju ima li distribucija tjednih prinosa dionice normalan oblik. Na hrvatskom tržištu kapitala većina dionica ima desnostranu ili pozitivnu asimetriju, te je vrh distribucije prinosa najčešće šiljastiji u odnosu na normalnu distribuciju. Dionica ATGR se ističe s vrijednosti

koeficijenta asimetrije koji odstupa od uobičajenog intervala. Vrijednost pokazatelja asimetrije od -2,561 ukazuje na izrazitu ljevostranost ili negativnu asimetriju distribucije prinosa. Dodatno, ista dionica se ističe s velikom vrijednosti pokazatelja zaobljenosti od 12,757 koji ukazuje na šiljastiji vrh od normalno zaobljene distribucije.

Tablica 2: Statistički podaci o prinosima na hrvatskom tržištu kapitala

		Statistics										
		CROBEX	ADPL	ADRS2	ATGR	ATPL	ERNT	HT	KOEI	PODR	RVP	ZABA
N	Valid	78	78	78	78	78	78	78	78	78	78	78
	Missing	0	0	0	0	0	0	0	0	0	0	0
Mean		,00126996	,00678920	,00311274	-,00092471	,01358399	,00236614	,00302466	,00139231	-,00051142	,00777000	,00321571
Std. Error of Mean		,001749363	,002913203	,002609574	,002406201	,007822777	,003000764	,002166747	,002460793	,002784407	,002882946	,004214433
Median		,00227538	,00622624	,00058692	,00003818	,01375432	,00143953	,00258128	-,00040411	,00008105	,00296366	,00431061
Std. Deviation		,015449956	,025728714	,023047137	,021250994	,069088897	,026502028	,019136188	,021733135	,024591218	,025461486	,037220867
Variance		,000	,001	,001	,000	,005	,001	,000	,000	,001	,001	,001
Skewness		-,930	,540	,815	-2,561	,341	-,824	,362	,467	-,002	,866	-1,619
Std. Error of Skewness		,272	,272	,272	,272	,272	,272	,272	,272	,272	,272	,272
Kurtosis		2,396	,570	3,034	12,757	-,148	4,574	,769	,709	1,143	1,404	9,585
Std. Error of Kurtosis		,538	,538	,538	,538	,538	,538	,538	,538	,538	,538	,538
Range		,092400	,130901	,152850	,158825	,325863	,166864	,097957	,108644	,133410	,139286	,290485
Minimum		-,060261	-,043905	-,056746	-,116881	-,123461	-,103427	-,037563	-,046543	-,066335	-,059447	-,191976
Maximum		,032140	,086997	,096104	,041944	,202402	,063438	,060394	,062102	,067075	,079840	,098509
Sum		,099057	,529558	,242794	-,072127	1,059551	,184559	,235923	,108600	-,039891	,606060	,250825
Percentiles	25	-,00683970	-,01255347	-,00910664	-,00598077	-,04607385	-,00812824	-,00832722	-,01543456	-,01224284	-,00800781	-,01051759
	50	,00227538	,00622624	,00058692	,00003818	,01375432	,00143953	,00258128	-,00040411	,00008105	,00296366	,00431061
	75	,01071805	,02323390	,01470485	,00849333	,06329845	,01395007	,01122226	,01710731	,01066735	,01602419	,01936758

Izvor: SPSS izračun autorice

Kako bi ispitali ima li distribucija prinosa u promatranom razdoblju normalan oblik, koristit će se Kolmogorov- Smirnov test. U tablici 3 prikazani su rezultati testa. Uspoređivanjem empirijske signifikantnosti testa s tabličnom vrijednosti testa može se zaključiti kako prinosi dionica poduzeća Adris Grupa d.d., Atlantic Grupa d.d., Ericsson Nikola Tesla d.d., HT d.d., Valmar Riviera d.d. i Zagrebačka banka d.d. nemaju normalan oblik. Prinosi dionica poduzeća AD Plastik d.d., Končar-Elektroindustrija d.d. i Podravka d.d. imaju normalan oblik. Distribucija prinosa dioničkog indeksa Zagrebačke burze u promatranom razdoblju je normalna.

Tablica 3: Kolmogorov- Smirnov test za hrvatsko tržište kapitala

One-Sample Kolmogorov-Smirnov Test												
		CROBEX	ADPL	ADRS2	ATGR	ATPL	ERNT	HT	KOEI	PODR	RNP	ZABA
N		78	78	78	78	78	78	78	78	78	78	78
Normal Parameters ^{a,b}	Mean	,00126996	,00678920	,00311274	-,00092471	,01358399	,00236614	,00302466	,00139231	-,00051142	,00777000	,00321571
	Std. Deviation	,015449956	,025728714	,023047137	,021250994	,069088897	,026502028	,019136188	,021733135	,024591218	,025461486	,037220867
Most Extreme Differences	Absolute	,088	,056	,107	,182	,061	,135	,101	,075	,097	,154	,118
	Positive	,047	,056	,107	,107	,061	,109	,101	,075	,097	,154	,104
	Negative	-,088	-,040	-,094	-,182	-,033	-,135	-,063	-,042	-,089	-,113	-,118
Test Statistic		,088	,056	,107	,182	,061	,135	,101	,075	,097	,154	,118
Asymp. Sig. (2-tailed)		,200 ^{c,d}	,200 ^{c,d}	,027 ^c	,000 ^c	,200 ^{c,d}	,001 ^c	,047 ^c	,200 ^{c,d}	,066 ^c	,000 ^c	,009 ^c

Izvor: SPSS izračun autorice

3.3. Ispitivanje distribucije prinosa na slovenskom tržištu kapitala

Analiza slovenskog tržišta kapitala vršit će se na dionicama koje su uvrštene u indeks SBITOP na Ljubljanskoj burzi. U izračun će se uzeti tjedne cijene zatvaranja od 1. siječnja 2016. godine do 30. lipnja 2017. godine.

Uvrštene dionice, prikazane u tablici 4, zadovoljavaju kriterij broja dana trgovanja, određene tržišne kapitalizacije, te kriterij likvidnosti. Deset odabranih dionica pripadaju velikim i stabilnim poduzećima iz različitih sektora slovenskog gospodarstva.

Tablica 4: Odabrane dionice s Ljubljanske burze

SIMBOL DIONICE	IZDAVATELJ DIONICE
CICG	Cinkarna Celje d.d.
GRVG	Gorenje d.d.
IEKG	Intereuropa d.d.
KRKG	Krka d.d.
LKPG	Luka Koper d.d.
PETG	Petrol d.d.
POSR	Pozavarovalnica Sava d.d.

TLSG	Telekom Slovenije d.d.
UKIG	Unior d.d.
ZVTG	Zavarovalnica Triglav d.d.

Izvor: Izrada autorice

Na temelju tjednih cijena odabranih dionica u Excelu su izračunati prinosi svake dionice za promatrano razdoblje.

Izračunati podaci tjednih prinosa dionica na slovenskom tržištu kapitala uspoređujemo mjerama deskriptivne statistike čime dobivamo detaljniji uvid u svojstva promatranih prinosa. U tablici 5 prikazani su statistički podaci o prinosima na slovenskom tržištu kapitala. Najveći prosječan prinos u promatranom razdoblju ima poduzeće Intereuropa d.d., dok se Luka Koper d.d. i Krka d.d. jedine ističu s negativnim prosječnim prinosom. Dionica Luka Koper d.d. osim najmanjeg prosječnog prinosa ima najveći rizik mjeren varijancom. Mjera asimetrije (skewness) i mjera zaobljenosti (kurtosis) sugeriraju ima li distribucija tjednih prinosa dionice normalan oblik. Na slovenskom tržištu kapitala jednak je broj dionica koje imaju desnostranu ili pozitivnu asimetriju i ljevostranu ili negativnu asimetriju. Vrhovi distribucije prinosa svih dionica su šiljastiji u odnosu na normalnu distribuciju. Dvije dionice se ističu s vrijednosti koeficijenta asimetrije koji odstupa od uobičajenog intervala. Dionica LKPG s vrijednosti koeficijenta asimetrije od -8,618 i dionica GRVG s vrijednosti koeficijenta asimetrije od -3,007 koji ukazuju na izrazitu ljevostranost ili negativnu asimetriju distribucije prinosa. Dodatno, iste dionice se ističu s velikom vrijednosti pokazatelja zaobljenosti. Dionica LKPG s vrijednosti pokazatelja zaobljenosti 75,484 i dionica GRVG s vrijednosti pokazatelja zaobljenosti 21,158 koji ukazuju na šiljastiji vrh od normalno zaobljene distribucije.

Tablica 5: Statistički podaci o prinosima na slovenskom tržištu kapitala

		Statistics										
		SBITOP	CICG	GRVG	IEKG	KRKG	LKPG	PETG	POSR	TLSG	UKIG	ZVTG
N	Valid	78	78	78	78	78	78	78	78	78	78	78
	Missing	0	0	0	0	0	0	0	0	0	0	0
Mean		,00172483	,01013141	,00403197	,01644237	-,00218111	-,03189574	,00490423	,00197770	,00194942	,00617572	,00079327
Std. Error of Mean		,001374563	,004742991	,006523313	,010395129	,002136965	,038303106	,002134716	,003123198	,002158080	,004306409	,002959370
Median		,00344283	,00436644	,00059157	,00739973	-,00182492	,00193749	,00613302	,00000000	-,00006329	,00000000	,00273325
Std. Deviation		,012139815	,041888959	,057612344	,091807298	,018873163	,338283877	,018853300	,027583340	,019059650	,038033171	,026136445
Variance		,000	,002	,003	,008	,000	,114	,000	,001	,000	,001	,001
Skewness		-,340	1,652	-3,007	,729	-,180	-8,618	-,378	,572	,976	1,004	-1,539
Std. Error of Skewness		,272	,272	,272	,272	,272	,272	,272	,272	,272	,272	,272
Kurtosis		-,254	5,935	21,158	1,860	,861	75,484	,893	2,056	3,247	2,148	6,441
Std. Error of Kurtosis		,538	,538	,538	,538	,538	,538	,538	,538	,538	,538	,538
Range		,056065	,284438	,512696	,553999	,096569	3,162096	,101135	,161900	,131505	,214540	,175847
Minimum		-,031439	-,072806	-,362326	-,201325	-,054808	-2,958051	-,050406	-,069433	-,053086	-,076390	-,117351
Maximum		,024626	,211632	,150370	,352674	,041761	,204045	,050730	,092468	,078419	,138150	,058496
Sum		,134536	,790250	,314493	1,282505	-,170126	-2,487868	,382530	,154261	,152055	,481706	,061875
Percentiles	25	-,00738511	-,01592801	-,01509638	-,04285341	-,01004163	-,01117683	-,00594317	-,01261732	-,00962637	-,01402111	-,01072867
	50	,00344283	,00436644	,00059157	,00739973	-,00182492	,00193749	,00613302	,00000000	-,00006329	,00000000	,00273325
	75	,00973604	,02688001	,02616096	,07260249	,00729914	,01915011	,01519069	,01419049	,01295079	,02080607	,01237103

Izvor: SPSS izračun autorice

Kako bi ispitali ima li distribucija prinosa u promatranom razdoblju normalan oblik, koristit će se Kolmogorov- Smirnov test. U tablici 6 prikazani su rezultati testa. Uspoređivanjem empirijske signifikatnosti testa s tabličnom vrijednosti testa može se zaključiti kako prinosi dionica poduzeća Cinkarna Celje d.d., Gorenje d.d., Krka d.d., Luka Koper d.d., Petrol d.d., Telekom Slovenije d.d., Unior d.d. i Zavarovalnica Triglav d.d. nemaju normalan oblik. Prinosi dionica poduzeća Intereuropa d.d. i Pozavarovalnica Sava d.d. imaju normalan oblik. Distribucija prinosa dioničkog indeksa Ljubljanske burze u promatranom razdoblju je normalna.

Tablica 6: Kolmogorov- Smirnov test za slovensko tržište kapitala

		One-Sample Kolmogorov-Smirnov Test										
		SBITOP	CICG	GRVG	IEKG	KRKG	LKPG	PETG	POSR	TLSG	UKIG	ZVTG
N		78	78	78	78	78	78	78	78	78	78	78
Normal Parameters ^{a,b}	Mean	,00172483	,01013141	,00403197	,01644237	-,00218111	-,03189574	,00490423	,00197770	,00194942	,00617572	,00079327
	Std. Deviation	,012139815	,041888959	,057612344	,091807298	,018873163	,338283877	,018853300	,027583340	,019059650	,038033171	,026136445
Most Extreme Differences	Absolute	,074	,123	,195	,085	,121	,423	,110	,095	,124	,134	,113
	Positive	,045	,123	,144	,085	,121	,336	,070	,095	,124	,134	,097
	Negative	-,074	-,095	-,195	-,063	-,108	-,423	-,110	-,080	-,080	-,080	-,113
Test Statistic		,074	,123	,195	,085	,121	,423	,110	,095	,124	,134	,113
Asymp. Sig. (2-tailed)		,200 ^{c,d}	,005 ^c	,000 ^c	,200 ^{c,d}	,007 ^c	,000 ^c	,020 ^c	,079 ^c	,005 ^c	,001 ^c	,016 ^c

Izvor: SPSS izračun autorice

3.4. Ispitivanje distribucije prinosa na srbijanskom tržištu kapitala

Analiza srbijanskog tržišta kapitala vršit će se na dionicama koje su uvrštene u indeks BELEXline na Beogradskoj burzi. U izračun će se uzeti tjedne cijene zatvaranja od 1. siječnja 2016. godine do 30. lipnja 2017. godine.

Uvrštene dionice, prikazane u tablici 7, zadovoljavaju kriterij broja dana trgovanja, određene tržišne kapitalizacije, te kriterij likvidnosti. Deset odabranih dionica pripadaju velikim i stabilnim poduzećima iz različitih sektora srbijanskog gospodarstva.

Tablica 7: Odabrane dionice s Beogradske burze

SIMBOL DIONICE	IZDAVATELJ DIONICE
AERO	Aerodrom Nikola Tesla d.d.
ALFA	Alfa plam d.d.
ENHL	Energoprojekt holding d.d.
FITO	Galenika- Fitofarmacija d.d.
IMPL	Impol Seval d.d.
KMBN	Komercijalna banka d.d.
MTLC	Metalac d.d.
NIIS	Nis d.d.
SJPT	Sojaprotein d.d.
TGAS	Messer Tehnogas d.d.

Izvor: Izrada autorice

Na temelju tjednih cijena odabranih dionica u Excelu su izračunati prinosi svake dionice za promatrano razdoblje.

Izračunati podaci tjednih prinosa dionica na srbijanskom tržištu kapitala uspoređujemo mjerama deskriptivne statistike čime dobivamo detaljniji uvid u svojstva promatranih prinosa. U tablici 8

prikazani su statistički podaci o prinosima na srbijanskom tržištu kapitala. Najveći prosječan prinos u promatranom razdoblju ima poduzeće Impol Seval d.d., dok se Metalac d.d. i Sojaprotein d.d. jedine ističu s negativnim prosječnim prinosom. Isto tako, dionica poduzeća Metalac d.d. ima najveći rizik mjeren varijancom. Mjera asimetrije (skewness) i mjera zaobljenosti (kurtosis) sugeriraju ima li distribucija tjednih prinosa dionice normalan oblik. Na srbijanskom tržištu kapitala većina dionica ima desnostranu ili pozitivnu asimetriju. Vrhovi distribucije prinosa svih dionica su šiljastiji u odnosu na normalnu distribuciju. Dvije dionice se ističu s vrijednosti koeficijenta asimetrije koji odstupa od uobičajenog intervala. Dionica IMPL s vrijednosti koeficijenta asimetrije od 3,699 koji ukazuje na izrazitu desnostranost ili pozitivnu asimetriju i dionica MTLC s vrijednosti koeficijenta asimetrije od -7,310 koji ukazuje na izrazitu ljevostranost ili negativnu asimetriju distribucije prinosa. Dodatno, iste dionice se ističu s velikom vrijednosti pokazatelja zaobljenosti. Dionica IMPL s vrijednosti pokazatelja zaobljenosti 28,870 i dionica MTLC s vrijednosti pokazatelja zaobljenosti 60,567 koji ukazuju na šiljastiji vrh od normalno zaobljene distribucije.

Tablica 8: Statistički podaci o prinosima na srbijanskom tržištu kapitala

		Statistics										
		BELEXline	AERO	ALFA	ENHL	FITO	IMPL	KMBN	MTLC	NIIS	SJPT	TGAS
N	Valid	78	78	78	78	78	78	78	78	78	78	78
	Missing	0	0	0	0	0	0	0	0	0	0	0
Mean		,00142229	,00139961	,00090923	,00429784	,00130752	,01443541	,00171194	-,00424070	,00152902	-,00937258	,00335344
Std. Error of Mean		,001549396	,004057016	,003102714	,003834501	,003471310	,007573264	,003389613	,009507485	,003133355	,004262373	,005162857
Median		,00072708	-,00094418	,00000000	,00240001	,00018386	,00684057	-,00169563	,00321957	,00067431	-,00330866	,00010001
Std. Deviation		,013683895	,035830595	,027402431	,033865397	,030657778	,066885256	,029936251	,083967833	,027673042	,037644255	,045597114
Variance		,000	,001	,001	,001	,001	,004	,001	,007	,001	,001	,002
Skewness		,097	,442	-,082	-,173	,087	3,699	,719	-7,310	,204	-,017	,291
Std. Error of Skewness		,272	,272	,272	,272	,272	,272	,272	,272	,272	,272	,272
Kurtosis		,765	4,205	1,596	1,686	1,261	28,870	3,617	60,567	3,122	,299	5,614
Std. Error of Kurtosis		,538	,538	,538	,538	,538	,538	,538	,538	,538	,538	,538
Range		,069480	,263554	,162427	,197237	,179226	,678207	,211212	,797767	,190196	,198249	,361769
Minimum		-,032729	-,120125	-,089584	-,106027	-,086595	-,208848	-,082238	-,693147	-,087011	-,096144	-,171414
Maximum		,036750	,143428	,072843	,091210	,092632	,469359	,128974	,104620	,103184	,102105	,190355
Sum		,110939	,109169	,070920	,335232	,101986	1,125962	,133531	-,330774	,119263	-,731061	,261568
Percentiles	25	-,00608212	-,01726502	-,01039197	-,01288040	-,01361406	-,01012697	-,01826450	-,01428818	-,01467844	-,03304278	-,01518492
	50	,00072708	-,00094418	,00000000	,00240001	,00018386	,00684057	-,00169563	,00321957	,00067431	-,00330866	,00010001
	75	,00906335	,01650659	,01423566	,02149338	,01592043	,03074919	,02206961	,02120221	,01385090	,01176006	,01621186

Izvor: SPSS izračun autorice

Kako bi ispitali ima li distribucija prinosa u promatranom razdoblju normalan oblik, koristit će se Kolmogorov- Smirnov test. U tablici 9 prikazani su rezultati testa. Uspoređivanjem empirijske signifikatnosti testa s tabličnom vrijednosti testa može se zaključiti kako prinosi dionica

poduzeća Aerodrom Nikola Tesla d.d., Alfa plam d.d., Energoprojekt holding d.d., Galenika Fitofarmacija d.d., Impol Seval d.d., Metalac d.d., Nis d.d. i Sojaprotein d.d. i Messer Tehnogas d.d. nemaju normalan oblik. Jedino prinosi dionica poduzeća Komercijalna banka d.d. imaju normalan oblik. Distribucija prinosa općeg indeksa Beogradske burze u promatranom razdoblju je normalna.

Tablica 9: Kolmogorov- Smirnov test za srbijansko tržište kapitala

One-Sample Kolmogorov-Smirnov Test												
		BELEXline	AERO	ALFA	ENHL	FITO	IMPL	KMBN	MTLC	NIIS	SJPT	TGAS
N		78	78	78	78	78	78	78	78	78	78	78
Normal Parameters ^{a,b}	Mean	,00142229	,00139961	,00090923	,00429784	,00130752	,01443541	,00171194	-,00424070	,00152902	-,00937258	,00335344
	Std. Deviation	,013683895	,035830595	,027402431	,033865397	,030657778	,066885256	,029936251	,083967833	,027673042	,037644255	,045597114
Most Extreme Differences	Absolute	,080	,104	,178	,106	,111	,176	,094	,279	,113	,101	,160
	Positive	,071	,104	,165	,083	,089	,176	,094	,231	,113	,056	,160
	Negative	-,080	-,092	-,178	-,106	-,111	-,149	-,073	-,279	-,092	-,101	-,126
Test Statistic		,080	,104	,178	,106	,111	,176	,094	,279	,113	,101	,160
Asymp. Sig. (2-tailed)		,200 ^{c,d}	,035 ^c	,000 ^c	,029 ^c	,019 ^c	,000 ^c	,086 ^c	,000 ^c	,015 ^c	,048 ^c	,000 ^c

Izvor: SPSS izračun autorice

4. FORMIRANJE EFIKASNIH GRANICA PRIMJENOM MV MODELA

4.1. Procjena efikasne granice na hrvatskom tržištu kapitala

Kako bi dobili optimalni portfelj koji će investitoru donijeti maksimalni prinos uz minimalnu razinu rizika potrebno je izračunati matricu varijanci i kovarijanci iz prethodno izračunatih podataka o prinosima dionica. Matrica varijanci i kovarijanci prikazana je tablicom 10.

Tablica 10: Matrica varijanci i kovarijanci dionica sa Zagrebačke burze

MATRICA S- MATRICA VARIJANCI I KOVARIJANCI										
	ADPL	ADRS2	ATGR	ATPL	ERNT	HT	KOEI	PODR	RIVP	ZABA
ADPL	0,000653	3,64E-05	9,04E-05	5,49E-05	6,63E-06	5,76E-05	0,000177	9,8E-05	5,45E-05	4,96E-05
ADRS2	3,64E-05	0,000524	0,000235	-3,4E-05	0,000238	0,000131	0,00013	0,000279	0,000149	0,000398
ATGR	9,04E-05	0,000235	0,000446	5,03E-05	0,000167	0,000116	0,000104	0,000218	0,000112	0,00031
ATPL	5,49E-05	-3,4E-05	5,03E-05	0,004712	-8,9E-05	-0,00011	0,000139	5,49E-06	-5,7E-05	0,000149
ERNT	6,63E-06	0,000238	0,000167	-8,9E-05	0,000693	0,000161	0,000121	0,000177	0,000109	0,000218
HT	5,76E-05	0,000131	0,000116	-0,00011	0,000161	0,000361	9,22E-05	5,51E-05	8,82E-05	8,84E-05
KOEI	0,000177	0,00013	0,000104	0,000139	0,000121	9,22E-05	0,000466	0,000239	5,42E-05	9,28E-05
PODR	9,8E-05	0,000279	0,000218	5,49E-06	0,000177	5,51E-05	0,000239	0,000597	0,000215	0,000389
RIVP	5,45E-05	0,000149	0,000112	-5,7E-05	0,000109	8,82E-05	5,42E-05	0,000215	0,00064	0,000323
ZABA	4,96E-05	0,000398	0,00031	0,000149	0,000218	8,84E-05	9,28E-05	0,000389	0,000323	0,001368

Izvor: Excel izračun autorice

Na glavnoj dijagonali matrice nalaze se varijance prinosa pojedinih dionica. Iz dobivenih rezultata možemo zaključiti kako je najrizičnija dionica ATPL sa varijancom od 0,004712, a najmanje rizična je dionica HT sa varijancom od 0,000361. Nadalje, vidljivo je da dionice ADRS2, ERNT, HT i RIVP imaju po jednu negativnu kovarijancu, a dionica ATPL ima tri negativne kovarijance, dok preostale dionice ADPL, ATGR, KOEI, PODR i ZABA imaju sve pozitivne kovarijance.


Sljedeća tablica prikazuje udjele koje pojedina dionica ima u portfelju pri različitim razinama rizika. Pri nižim razinama rizika veći broj dionica ima udio u portfelju dok se s povećanjem rizika broj dionica smanjuje sve dok portfelj ne čini samo jedna dionica. Ta opcija je najrizičnija za investitora, ali nosi najveći prinos. Ukoliko investitor preferira maksimalni prinos od 1,36% ili nema averziju prema riziku cjelokupan iznos će uložiti u dionicu ATPL.

Tablica 11: Efikasni portfelji na hrvatskom tržištu kapitala

ADPL	ADRS2	ATGR	ATPL	ERNT	HT	KOEI	PODR	RIVP	ZABA	σ	E(R π)
0,1469	0,0543	0,1204	0,0370	0,0719	0,2682	0,1348	0,0223	0,1383	0,0000	1,27%	0,38%
0,1322	0,0483	0,1083	0,1333	0,0647	0,2414	0,1213	0,0201	0,1245	0,0000	1,44%	0,48%
0,1175	0,0423	0,0963	0,2296	0,0575	0,2146	0,1078	0,0178	0,1106	0,0000	1,85%	0,58%
0,1028	0,0362	0,0843	0,3259	0,0503	0,1877	0,0943	0,0156	0,0968	0,0000	2,39%	0,67%
0,0881	0,0302	0,0722	0,4222	0,0431	0,1609	0,0809	0,0134	0,0830	0,0000	2,98%	0,77%
0,0734	0,0242	0,0602	0,5185	0,0359	0,1341	0,0674	0,0111	0,0691	0,0000	3,60%	0,87%
0,0587	0,0181	0,0481	0,6148	0,0288	0,1073	0,0539	0,0089	0,0553	0,0000	4,24%	0,97%
0,0441	0,0121	0,0361	0,7111	0,0216	0,0805	0,0404	0,0067	0,0415	0,0000	4,89%	1,07%
0,0294	0,0060	0,0241	0,8074	0,0144	0,0536	0,0270	0,0045	0,0277	0,0000	5,54%	1,16%
0,0147	0,0000	0,0120	0,9037	0,0072	0,0268	0,0135	0,0022	0,0138	0,0000	6,20%	1,26%
0,0000	0,0000	0,0000	1,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	6,86%	1,36%

Izvor: Excel izračun autorice

Na temelju različitih kombinacija ulaganja formiramo efikasnu granicu. Svi portfelji koji leže na efikasnoj granici su efikasni s obzirom na prinos i rizik, a u koji portfelj će investitor uložiti ovisi o njegovoj sklonosti riziku i ciljevima u pogledu prinosa.



Slika 7: Efikasna granica na hrvatskom tržištu kapitala

Izvor: Excel izračun autorice

4.2. Procjena efikasne granice na slovenskom tržištu kapitala

Kako bi dobili optimalni portfelj koji će investitoru donijeti maksimalni prinos uz minimalnu razinu rizika potrebno je izračunati matricu varijanci i kovarijanci iz prethodno izračunatih podataka o prinosima dionica. Matrica varijanci i kovarijanci prikazana je tablicom 12.

Tablica 12: Matrica varijanci i kovarijanci dionica s Ljubljanske burze

	MATRICA S- MATRICA VARIJANCI I KOVARIJANCI									
	CICG	GRVG	IEKG	KRKG	LKPG	PETG	POSR	TLSG	UKIG	ZVTG
CICG	0,001732	-0,00109	0,000168	-8,4E-05	-0,00109	0,000117	0,000237	0,000173	-5,3E-05	9,26E-05
GRVG	-0,00109	0,003277	-0,00033	0,000231	-0,00014	-7,3E-05	7,16E-05	3,12E-06	-9,7E-05	0,000125
IEKG	0,000168	-0,00033	0,008321	-0,00019	-0,00185	-0,00018	0,000325	6,47E-05	0,00023	-1,9E-05
KRKG	-8,4E-05	0,000231	-0,00019	0,000352	-4,2E-06	3,12E-05	4,09E-05	7,22E-05	-9,8E-05	-5,9E-06
LKPG	-0,00109	-0,00014	-0,00185	-4,2E-06	0,112969	0,000762	-0,00055	-0,00275	0,000456	-0,00159
PETG	0,000117	-7,3E-05	-0,00018	3,12E-05	0,000762	0,000351	9,06E-05	-4E-05	5,86E-05	8,07E-05
POSR	0,000237	7,16E-05	0,000325	4,09E-05	-0,00055	9,06E-05	0,000751	0,000126	-0,0001	0,000298
TLSG	0,000173	3,12E-06	6,47E-05	7,22E-05	-0,00275	-4E-05	0,000126	0,000359	-0,00012	0,000136
UKIG	-5,3E-05	-9,7E-05	0,00023	-9,8E-05	0,000456	5,86E-05	-0,0001	-0,00012	0,001428	-8,3E-06
ZVTG	9,26E-05	0,000125	-1,9E-05	-5,9E-06	-0,00159	8,07E-05	0,000298	0,000136	-8,3E-06	0,000674

Izvor: Excel izračun autorice

Na glavnoj dijagonali matrice nalaze se varijance prinosa pojedinih dionica. Iz dobivenih rezultata možemo zaključiti kako je najrizičnija dionica LKPG sa varijancom od 0,112969 a najmanje rizična je dionica KRKG sa varijancom od 0,000352. Nadalje, vidljivo je da sve dionice imaju najmanje dvije negativne kovarijance, kao dionice POSR, a najviše sedam negativnih kovarijanci ima dionica LKPG.


Sljedeća tablica prikazuje udjele koje pojedina dionica ima u portfelju pri različitim razinama rizika. Pri nižim razinama rizika veći broj dionica ima udio u portfelju dok se s povećanjem rizika broj dionica smanjuje sve dok portfelj ne čini samo jedna dionica. Ta opcija je najrizičnija za investitora, ali nosi najveći prinos. Ukoliko investitor preferira maksimalni prinos od 1,49% ili nema averziju prema riziku cjelokupan iznos će uložiti u dionicu IEKG.

Tablica 13: Efikasni portfelji na slovenskom tržištu kapitala

CICG	GRVG	IEKG	KRKG	LKPG	PETG	POSR	TLSG	UKIG	ZVTG	$\sigma\pi$	$E(R\pi)$
0,0764	0,0582	0,0271	0,1343	0,0052	0,2907	0,0000	0,2783	0,1010	0,0287	1,00%	0,36%
0,0688	0,0524	0,1244	0,1208	0,0047	0,2617	0,0000	0,2505	0,0909	0,0259	1,40%	0,47%
0,0612	0,0466	0,2217	0,1074	0,0042	0,2326	0,0000	0,2226	0,0808	0,0230	2,12%	0,59%
0,0535	0,0408	0,3190	0,0940	0,0037	0,2035	0,0000	0,1948	0,0707	0,0201	2,95%	0,70%
0,0459	0,0349	0,4163	0,0806	0,0031	0,1744	0,0000	0,1670	0,0606	0,0172	3,81%	0,81%
0,0382	0,0291	0,5136	0,0671	0,0026	0,1454	0,0000	0,1392	0,0505	0,0144	4,68%	0,93%
0,0306	0,0233	0,6108	0,0537	0,0021	0,1163	0,0000	0,1113	0,0404	0,0115	5,56%	1,04%
0,0229	0,0175	0,7081	0,0403	0,0016	0,0872	0,0000	0,0835	0,0303	0,0086	6,45%	1,15%
0,0153	0,0116	0,8054	0,0269	0,0010	0,0581	0,0000	0,0557	0,0202	0,0057	7,34%	1,26%
0,0076	0,0058	0,9027	0,0134	0,0005	0,0291	0,0000	0,0278	0,0101	0,0029	8,23%	1,38%
0,0000	0,0000	1,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	9,12%	1,49%

Izvor: Excel izračun autorice

Na temelju različitih kombinacija ulaganja formiramo efikasnu granicu. Svi portfelji koji leže na efikasnoj granici su efikasni s obzirom na prinos i rizik, a u koji portfelj će investitor uložiti ovisi o njegovoj sklonosti riziku i ciljevima u pogledu prinosa.



Slika 8: Efikasna granica na slovenskom tržištu kapitala

Izvor: Excel izračun autorice

4.3. Procjena efikasne granice na srbijanskom tržištu kapitala

Kako bi dobili optimalni portfelj koji će investitoru donijeti maksimalni prinos uz minimalnu razinu rizika potrebno je izračunati matricu varijanci i kovarijanci iz prethodno izračunatih podataka o prinosima dionica. Matrica varijanci i kovarijanci prikazana je tablicom 14.

Tablica 14: Matrica varijanci i kovarijanci dionica s Beogradske burze

	MATRICA S- MATRICA VARIJANCI I KOVARIJANCI									
	AERO	ALFA	ENHL	FITO	IMPL	KMBN	MTLC	NIIS	SJPT	TGAS
AERO	0,001267	0,00012	0,000437	0,000135	-0,0002	0,000155	-9,5E-06	0,000329	-8,9E-05	0,000372
ALFA	0,00012	0,000741	0,000186	0,000253	3,36E-05	0,000183	-0,00018	0,000163	7,96E-05	-3,4E-05
ENHL	0,000437	0,000186	0,001132	0,00019	-0,00024	0,00016	0,000148	0,000302	-0,00016	0,000246
FITO	0,000135	0,000253	0,00019	0,000928	9,15E-05	0,000296	-0,00029	0,00022	0,000111	7,54E-05
IMPL	-0,0002	3,36E-05	-0,00024	9,15E-05	0,004416	6,44E-05	3,93E-05	-8E-05	0,000236	-0,00043
KMBN	0,000155	0,000183	0,00016	0,000296	6,44E-05	0,000885	7,2E-05	0,000147	0,000253	0,000138
MTLC	-9,5E-06	-0,00018	0,000148	-0,00029	3,93E-05	7,2E-05	0,00696	-9,4E-05	0,000541	0,000381
NIIS	0,000329	0,000163	0,000302	0,00022	-8E-05	0,000147	-9,4E-05	0,000756	0,000146	-5,1E-05
SJPT	-8,9E-05	7,96E-05	-0,00016	0,000111	0,000236	0,000253	0,000541	0,000146	0,001399	8,01E-05
TGAS	0,000372	-3,4E-05	0,000246	7,54E-05	-0,00043	0,000138	0,000381	-5,1E-05	8,01E-05	0,002052

Izvor: Excel izračun autorice

Na glavnoj dijagonali matrice nalaze se varijance prinosa pojedinih dionica. Iz dobivenih rezultata možemo zaključiti kako je najrizičnija dionica MTLC sa varijancom od 0,00696, a najmanje rizična je dionica ALFA sa varijancom od 0,000741. Nadalje, vidljivo je da dionice imaju najmanje jednu negativnu kovarijancu, osim dionice KMBN koja jedina ima sve pozitivne kovarijance. Najviše, odnosno četiri negativne kovarijance ima dionica MTLC.


Sljedeća tablica prikazuje udjele koje pojedina dionica ima u portfelju pri različitim razinama rizika. Pri nižim razinama rizika veći broj dionica ima udio u portfelju dok se s povećanjem rizika broj dionica smanjuje dok portfelj ne čini samo jedna dionica. Ta opcija je najrizičnija za investitora, ali nosi najveći prinos. Ukoliko investitor preferira maksimalni prinos od 1,44% ili nema averziju prema riziku cjelokupan iznos će uložiti u dionicu IMPL.

Tablica 15: Efikasni portfelji na srbijanskom tržištu kapitala

AERO	ALFA	ENHL	FITO	IMPL	KMBN	MTLC	NIIS	SJPT	TGAS	σ	E(R _π)
0,0676	0,2002	0,0851	0,0918	0,0642	0,0942	0,0293	0,1646	0,1060	0,0970	1,55%	0,13%
0,0608	0,1802	0,0766	0,0827	0,1578	0,0847	0,0263	0,1482	0,0954	0,0873	1,68%	0,26%
0,0541	0,1602	0,0681	0,0735	0,2513	0,0753	0,0234	0,1317	0,0848	0,0776	2,02%	0,39%
0,0473	0,1402	0,0596	0,0643	0,3449	0,0659	0,0205	0,1152	0,0742	0,0679	2,48%	0,52%
0,0405	0,1201	0,0511	0,0551	0,4385	0,0565	0,0176	0,0988	0,0636	0,0582	3,02%	0,66%
0,0338	0,1001	0,0425	0,0459	0,5321	0,0471	0,0146	0,0823	0,0530	0,0485	3,59%	0,79%
0,0270	0,0801	0,0340	0,0367	0,6257	0,0377	0,0117	0,0659	0,0424	0,0388	4,18%	0,92%
0,0203	0,0601	0,0255	0,0276	0,7193	0,0282	0,0088	0,0494	0,0318	0,0291	4,78%	1,05%
0,0135	0,0400	0,0170	0,0184	0,8128	0,0188	0,0059	0,0329	0,0212	0,0194	5,40%	1,18%
0,0068	0,0200	0,0085	0,0092	0,9064	0,0094	0,0029	0,0165	0,0106	0,0097	6,02%	1,31%
0,0000	0,0000	0,0000	0,0000	1,0000	0,0000	0,0000	0,0000	0,0000	0,0000	6,65%	1,44%

Izvor: Excel izračun autorice


Na temelju različitih kombinacija ulaganja formiramo efikasnu granicu. Svi portfelji koji leže na efikasnjoj granici su efikasni s obzirom na prinos i rizik, a u koji portfelj će investitor uložiti ovisi o njegovoj sklonosti riziku i ciljevima u pogledu prinosa.



Slika 9: Efikasna granica na srbijanskom tržištu kapitala

Izvor: Excel izračun autorice

4.4. Usporedba efikasnih granica na hrvatskom, slovenskom i srbijanskom tržištu dobivenih primjenom MV modela



Slika 10: Efikasne granice na hrvatskom, slovenskom i srbijanskom tržištu kapitala izračunate primjenom MV modela

Izvor: Excel izračun autorice

Slika 10 prikazuje efikasne granice na hrvatskom, slovenskom i srbijanskom tržištu izračunate primjenom Markowitzeva modela. Ukoliko usporedimo efikasne granice možemo vidjeti razlike u očekivanim prinosima na različitim tržištima kapitala. Pri nižim razinama rizika najbolji omjer prinosa i rizika je na slovenskom tržištu kapitala, dok se najmanji prinos ostvaruje na srbijanskom tržištu kapitala. Međutim, pri nešto višim razinama rizika portfelj dionica sa hrvatskog tržišta kapitala nosi bolje rezultate od portfelja oblikovanog na slovenskom i srbijanskom tržištu. Pri višim razinama rizika, najbolji omjer prinosa i rizika pruža portfelj sastavljen od dionica sa srbijanskog tržišta kapitala.

5. FORMIRANJE EFIKASNIH GRANICA DONJOM POLU-VARIJANCOM

5.1. Procjena efikasne granice na hrvatskom tržištu kapitala donjom polu-varijancom kao mjerom rizika

Budući da su na hrvatskom tržištu kapitala u izračun uzete dionice za čije prinose smo prethodno statističkim testovima utvrdili da nemaju oblik normalne distribucije, pretpostavke Markowitzevog modela nisu ispunjene. Prinosi dionica ADRS2, ATGR, ERNT, HT, RIVP i ZABA u promatranom razdoblju nisu normalno distribuirani zbog čega varijanca nije adekvatna mjera rizika. Stoga će se za procjenu efikasne granice kao mjera rizika koristiti donja polu-varijanca. Donja polu-varijanca u promatranje uzima samo one prinose koji su manji od očekivanog prinosa i za njih računa prosječno kvadratno odstupanje. Za odabrane dionice s hrvatskog tržišta kapitala rizik mjeren polu-varijancom naveden je u donjoj tablici. Vidljivo je da je rizik mjeren polu-varijancom manji od rizika mjerenog varijancom. Također, dionica ATPL koja ima najveći rizik mjeren varijancom, isto tako ima najveći rizik mjeren polu-varijancom.

Tablica 16: Polu-varijanca tjednih prinosa dionica na hrvatskom tržištu kapitala

	ADPL	ADRS2	ATGR	ATPL	ERNT	HT	KOEI	PODR	RIVP	ZABA
Varijanca	0,000653	0,000524	0,000446	0,004712	0,000693	0,000361	0,000466	0,000597	0,000640	0,001368
Polu-varijanca	0,000288	0,000213	0,000311	0,002166	0,000379	0,000167	0,000207	0,000299	0,000233	0,000839

Izvor: Excel izračun autorice

Problem pronalaženja portfelja koji ima minimalan rizik mjeren polu-varijancom i prinos jednak ili veći od zadane konstante svodi se na rješavanje problema kvadratnog programiranja. Budući da se radi o velikom broju parametara za izračun se koristi Excel Premium Solver. U tablici 17. prikazani su dobiveni rezultati za deset različitih konstanti.


Tablica 17: Efikasni portfelji na hrvatskom tržištu kapitala s donjom polu-varijancom kao mjerom rizika

ADPL	ADRS2	ATGR	ATPL	ERNT	HT	KOEI	PODR	RIVP	ZABA	DPVAR	DPSD	OČ PRINOS
0,1489	0,0737	0,0908	0,0552	0,0569	0,3258	0,0911	0,0456	0,1121	0,0000	0,000078	0,008818	0,40%
0,2212	0,1865	0,0000	0,0756	0,0174	0,2763	0,0452	0,0519	0,1258	0,0000	0,000082	0,009052	0,50%
0,2630	0,1329	0,0000	0,0594	0,0757	0,1749	0,0000	0,0000	0,2942	0,0000	0,000085	0,009218	0,60%
0,3131	0,0774	0,0000	0,1047	0,0000	0,1499	0,0000	0,0000	0,3549	0,0000	0,000112	0,010578	0,70%
0,2857	0,0000	0,0000	0,1302	0,0000	0,0520	0,0000	0,0000	0,5321	0,0000	0,000145	0,012045	0,80%
0,2131	0,0000	0,0000	0,2475	0,0000	0,0000	0,0000	0,0000	0,5394	0,0000	0,000231	0,015202	0,90%
0,0000	0,0000	0,0000	0,3836	0,0000	0,0000	0,0000	0,0000	0,6164	0,0000	0,000420	0,020503	1,00%
0,0000	0,0000	0,0000	0,7276	0,0000	0,0000	0,0000	0,0000	0,2724	0,0000	0,001176	0,034296	1,20%
0,0000	0,0000	0,0000	0,8996	0,0000	0,0000	0,0000	0,0000	0,1004	0,0000	0,001759	0,041946	1,30%
0,0000	0,0000	0,0000	1,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,002163	0,046511	1,36%

Izvor: Excel izračun autorice

Primjenom donje polu-varijance kao mjere rizika izračunati su efikasni portfelji koji se po zastupljenosti pojedinih dionica razlikuju od efikasnih portfelja izračunatih Markowitzevim modelom. Pri nižim razinama rizika veći broj dionica ima udio u portfelju, dok se povećanjem rizika broj dionica smanjuje sve dok portfelj ne čini samo jedna dionica. Ta opcija za investitora je najrizičnija, ali nosi najveći očekivani prinos. Ukoliko investitor preferira maksimalni prinos od 1,36% cjelokupni iznos će uložiti u dionicu ATPL.

Na temelju različitih kombinacija ulaganja formiramo efikasnu granicu. Svi portfelji koji leže na efikasnoj granici su efikasni s obzirom na prinos i rizik, a u koji portfelj će investitor uložiti ovisi o njegovoj sklonosti riziku i ciljevima u pogledu prinosa.



Slika 11: Efikasna granica na hrvatskom tržištu kapitala s donjom polu-standardnom devijacijom kao mjerom rizika

Izvor: Excel izračun autorice

5.2. Procjena efikasne granice na slovenskom tržištu kapitala donjom polu-varijancom kao mjerom rizika

Budući da su na slovenskom tržištu kapitala u izračun uzete dionice za čije prinose smo prethodno statističkim testovima utvrdili da nemaju oblik normalne distribucije, pretpostavke Markowitzevog modela nisu ispunjene. Prinosi dionica CICG, GRVG, KRKG, LKPG, PETG, TLSG, UKIG i ZVTG u promatranom razdoblju nisu normalno distribuirani zbog čega varijanca nije adekvatna mjera rizika. Stoga će se za procjenu efikasne granice kao mjera rizika koristiti donja polu-varijanca. Donja polu-varijanca u promatranje uzima samo one prinose koji su manji od očekivanog prinosa i za njih računa prosječno kvadratno odstupanje. Za odabrane dionice sa slovenskog tržišta kapitala rizik mjeran polu-varijancom naveden je u donjoj tablici. Vidljivo je da je rizik mjeran polu-varijancom manji od rizika mjenog varijancom. Također, dionica LKPG koja ima najveći rizik mjeran varijancom, isto tako ima najveći rizik mjeran polu-varijancom.

Tablica 18: Polu-varijanca tjednih prinosa dionica na slovenskom tržištu kapitala

	CICG	GRVG	IEKG	KRKG	LKPG	PETG	POSR	TLSG	UKIG	ZVTG
Varijanca	0,001732	0,003277	0,008321	0,000352	0,112969	0,000351	0,000751	0,000359	0,001428	0,000674
Polu varijanca	0,000576	0,002188	0,003481	0,000184	0,109963	0,000196	0,000326	0,000136	0,000534	0,000428

Izvor: Excel izračun autorice

Problem pronalaženja portfelja koji ima minimalan rizik mjeren polu-varijancom i prinos jednak ili veći od zadane konstante svodi se na rješavanje problema kvadratnog programiranja. Budući da se radi o velikom broju parametara za izračun se koristi Excel Premium Solver. U tablici 19. prikazani su dobiveni rezultati za deset različitih konstanti.


Tablica 19: Efikasni portfelji na slovenskom tržištu kapitala s donjom polu-varijancom kao mjerom rizika

CICG	GRVG	IEKG	KRKG	LKPG	PETG	POSR	TLSG	UKIG	ZVTG	DPVAR	DPSD	OČ PRINOS
0,0698	0,0605	0,0214	0,1780	0,0079	0,2114	0,0000	0,2774	0,1154	0,0582	0,000042	0,006458	0,30%
0,1105	0,0575	0,0440	0,1640	0,0066	0,2677	0,0000	0,2317	0,1181	0,0000	0,000050	0,007076	0,40%
0,1116	0,0756	0,0333	0,0390	0,0000	0,3718	0,0000	0,2364	0,1323	0,0000	0,000059	0,007703	0,50%
0,1478	0,1059	0,0538	0,0000	0,0000	0,4683	0,0000	0,1159	0,1084	0,0000	0,000080	0,008943	0,60%
0,2154	0,1068	0,0875	0,0000	0,0000	0,4249	0,0000	0,0370	0,1284	0,0000	0,000113	0,010633	0,70%
0,3558	0,1270	0,1024	0,0000	0,0000	0,2850	0,0000	0,0000	0,1298	0,0000	0,000160	0,012645	0,80%
0,4291	0,1493	0,1550	0,0000	0,0000	0,1132	0,0000	0,0000	0,1534	0,0000	0,000248	0,015739	0,90%
0,5730	0,1396	0,1809	0,0000	0,0000	0,0000	0,0000	0,0000	0,1066	0,0000	0,000361	0,018988	1,00%
0,4662	0,0000	0,5338	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,001246	0,035304	1,35%
0,0000	0,0000	1,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,003480	0,058995	1,64%

Izvor: Excel izračun autorice

Primjenom donje polu-varijance kao mjere rizika izračunati su efikasni portfelji koji se po zastupljenosti pojedinih dionica razlikuju od efikasnih portfelja izračunatih Markowitzevim modelom. Pri nižim razinama rizika veći broj dionica ima udio u portfelju, dok se povećanjem rizika broj dionica smanjuje sve dok portfelj ne čini samo jedna dionica. Ta opcija za investitora je najrizičnija, ali nosi najveći očekivani prinos. Ukoliko investitor preferira maksimalni prinos od 1,64% cjelokupni iznos će uložiti u dionicu IEKG.

Na temelju različitih kombinacija ulaganja formiramo efikasnu granicu. Svi portfelji koji leže na efikasnoj granici su efikasni s obzirom na prinos i rizik, a u koji portfelj će investitor uložiti ovisi o njegovoj sklonosti riziku i ciljevima u pogledu prinosa.



Slika 12: Efikasna granica na slovenskom tržištu kapitala s donjom polu-standardnom devijacijom kao mjerom rizika

Izvor: Excel izračun autorice

5.3. Procjena efikasne granice na srbijanskom tržištu kapitala donjom polu-varijancom kao mjerom rizika

Budući da su na srbijanskom tržištu kapitala u izračun uzete dionice za čije prinose smo prethodno statističkim testovima utvrdili da nemaju oblik normalne distribucije, pretpostavke Markowitzevog modela nisu ispunjene. Prinosi dionica AERO, ALFA, ENHL, FITO, IMPL, MTLC, NIIS, SJPT i TGAS u promatranom razdoblju nisu normalno distribuirani zbog čega varijanca nije adekvatna mjera rizika. Stoga će se za procjenu efikasne granice kao mjera rizika koristiti donja polu-varijanca. Donja polu-varijanca u promatranje uzima samo one prinose koji su manji od očekivanog prinosa i za njih računa prosječno kvadratno odstupanje. Za odabrane dionice sa srbijanskog tržišta kapitala rizik mjeren polu-varijancom naveden je u donjoj tablici. Vidljivo je da je rizik mjeren polu-varijancom manji od rizika mjerenog varijancom. Također, dionica MTLC koja ima najveći rizik mjeren varijancom, isto tako ima najveći rizik mjeren polu-varijancom.

Tablica 20: Polu-varijanca tjednih prinosa dionica na srbijanskom tržištu kapitala

	AERO	ALFA	ENHL	FITO	IMPL	KMBN	MTLC	NIIS	SJPT	TGAS
Varijanca	0,001267	0,000741	0,001132	0,000928	0,004416	0,000885	0,006960	0,000756	0,001399	0,002052
Polu varijanca	0,000570	0,000370	0,000579	0,000455	0,001220	0,000377	0,006314	0,000359	0,000739	0,000948

Izvor: Excel izračun autorice

Problem pronalaženja portfelja koji ima minimalan rizik mjeren polu-varijancom i prinos jednak ili veći od zadane konstante svodi se na rješavanje problema kvadratnog programiranja. Budući da se radi o velikom broju parametara za izračun se koristi Excel Premium Solver. U tablici 21 prikazani su dobiveni rezultati za deset različitih konstanti.


Tablica 21: Efikasni portfelji na srbijanskom tržištu kapitala s donjom polu-varijancom kao mjerom rizika

AERO	ALFA	ENHL	FITO	IMPL	KMBN	MTLC	NIIS	SJPT	TGAS	DPVAR	DPSD	OČ PRINOS
0,0000	0,1890	0,0862	0,1049	0,1432	0,1355	0,0311	0,1490	0,0483	0,1129	0,000126	0,011237	0,30%
0,1164	0,1159	0,1408	0,1080	0,1545	0,1762	0,0102	0,0548	0,0000	0,1230	0,000150	0,012243	0,40%
0,0774	0,1077	0,1698	0,0103	0,2176	0,1464	0,0047	0,1168	0,0000	0,1494	0,000162	0,012723	0,50%
0,0414	0,0834	0,2515	0,0268	0,2765	0,1384	0,0027	0,0376	0,0000	0,1417	0,000182	0,013495	0,60%
0,0393	0,0684	0,2851	0,0000	0,3446	0,0766	0,0000	0,0397	0,0000	0,1463	0,000217	0,014741	0,70%
0,0000	0,0433	0,2181	0,0258	0,4303	0,0675	0,0008	0,0289	0,0000	0,1851	0,000248	0,015733	0,80%
0,0000	0,0014	0,2473	0,0016	0,4970	0,0435	0,0000	0,0092	0,0000	0,2000	0,000303	0,017410	0,90%
0,0000	0,0000	0,4375	0,0000	0,5625	0,0000	0,0000	0,0000	0,0000	0,0000	0,000447	0,021140	1,00%
0,0000	0,0000	0,1909	0,0000	0,8091	0,0000	0,0000	0,0000	0,0000	0,0000	0,000774	0,027820	1,25%
0,0000	0,0000	0,0000	0,0000	1,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,001220	0,034927	1,44%

Izvor: Excel izračun autorice

Primjenom donje polu-varijance kao mjere rizika izračunati su efikasni portfelji koji se po zastupljenosti pojedinih dionica razlikuju od efikasnih portfelja izračunatih Markowitzevim modelom. Pri nižim razinama rizika veći broj dionica ima udio u portfelju, dok se povećanjem rizika broj dionica smanjuje sve dok portfelj ne čini samo jedna dionica. Ta opcija za investitora je najrizičnija, ali nosi najveći očekivani prinos. Ukoliko investitor preferira maksimalni prinos od 1,44% cjelokupni iznos će uložiti u dionicu IMPL.


Na temelju različitih kombinacija ulaganja formiramo efikasnu granicu. Svi portfelji koji leže na efikasnoj granici su efikasni s obzirom na prinos i rizik, a u koji portfelj će investitor uložiti ovisi o njegovoj sklonosti riziku i ciljevima u pogledu prinosa.



Slika 13: Efikasna granica na srbijanskom tržištu kapitala s donjom polu-standardnom devijacijom kao mjerom rizika

Izvor: Excel izračun autorice

5.4. Usporedba efikasnih granica na hrvatskom, slovenskom i srbijanskom tržištu kapitala izračunatih primjenom donje polu-varijance kao mjere rizika



Slika 14: Efikasne granice na hrvatskom, slovenskom i srbijanskom tržištu kapitala izračunate primjenom donje polu-varijance kao mjere rizika

Izvor: Excel izračun autorice

Slika 14 prikazuje efikasne granice na hrvatskom, slovenskom i srbijanskom tržištu izračunate primjenom modela koji koristi donju polu-varijancu (donju polu-standardnu devijaciju) kao mjeru rizika. Ukoliko usporedimo efikasne granice možemo vidjeti razlike u očekivanim prinosima na različitim tržištima kapitala. Pri nižim razinama rizika najbolji omjer prinosa i rizika je na slovenskom tržištu kapitala, dok se najmanji prinos ostvaruje na srbijanskom tržištu kapitala. Međutim, pri višim razinama rizika portfelj dionica sa srbijanskog tržišta kapitala nosi bolje rezultate od portfelja oblikovanog na hrvatskom i slovenskom tržištu.

5.5. Usporedba efikasnih granica dobivenih varijancom kao mjerom rizika i donjom polu-varijancom kao mjerom rizika

Ako usporedimo odnos efikasnih granica dobivenih MV modelom i odnos efikasnih granica dobivenih donjom polu-varijancom uočavamo određene sličnosti. U oba slučaja slovensko tržište kapitala ima najveći raspon rizika, a najmanji raspon rizika je na srbijanskom tržištu kapitala. Kod obaju modela na vrlo niskim razinama rizika portfelji oblikovani na slovenskom tržištu kapitala pružaju najbolje rezultate, dok su najlošiji rezultati na srbijanskom tržištu kapitala. Međutim, razlika između modela uočava se kod srednjih razina rizika. Kod efikasnih portfelja dobivenih primjenom varijance pri srednjim razinama rizika, hrvatsko tržište ima najbolji omjer prinosa i rizika. Kod efikasnih portfelja dobivenih primjenom donje polu-varijance pri srednjim razinama rizika, slovensko tržište ima najbolji omjer prinosa i rizika. Pri višim razinama rizika kod obaju modela srbijansko tržište ima najbolji omjer prinosa i rizika, ali kod MV modela najlošiji rezultat u višim razinama rizika je na slovenskom tržištu kapitala, dok je najlošiji rezultat kod primjene donje polu-varijance postignut na hrvatskom tržištu kapitala. Sličnosti dvaju modela opet se uočavaju pri vrlo visokim razinama rizika, gdje slovensko tržište kapitala zbog svojeg velikog raspona rizika može biti atraktivno investitorima sklonima riziku.

Veće razlike između dvaju modela vidljive su u sastavima efikasnih portfelja. Na hrvatskom tržištu kapitala najzastupljenije dionice u efikasnim portfeljima dobivenima primjenom varijance su ADPL, ATPL i HT. Najzastupljenije dionice u efikasnim portfeljima dobivenim primjenom donje polu-varijance su dionice ADPL, ATPL i RIVP. Povećavanjem razine rizika kod modela s donjom polu-varijancom manji broj dionica sačinjava portfelj nego li je to slučaj kod MV modela. Tako na primjer dionica ATGR ulazi u sastav samo najmanje rizičnog portfelja kod modela s donjom polu-varijancom, a kod modela s varijancom ista dionica ulazi u sastav svih portfelja osim najrizičnijeg. U oba modela dionica ZABA nije sastavni dio nijednog efikasnog portfelja. Najrizičniji efikasni portfelj s maksimalnim prinosom od 1,36% je ulaganje cjelokupnog iznosa u dionicu ATPL, što je postignuto kod oba modela korištenjem različite mjere rizika.

Na slovenskom tržištu kapitala najzastupljenije dionice u efikasnim portfeljima dobivenima primjenom varijance su IEKG, PETG i TLSG. Najzastupljenije dionice u efikasnim portfeljima

dobivenim primjenom donje polu-varijance su dionice CICG, IEKG, PETG i UKIG. Na slovenskom tržištu kapitala, jednako kao i kod hrvatskog tržišta povećavanjem rizika manji broj dionica sačinjava efikasni portfelj dobiven primjenom donje polu-varijance nego li je to slučaj kod efikasnih portfelja dobivenih primjenom varijance. Tako na primjer dionica KRKG ulazi u sastav tri efikasna portfelja kod modela s donjom polu-varijancom, a kod modela s varijancom ista dionica ulazi u sastav svih portfelja osim najrizičnijeg. U oba modela dionica POSR nije sastavni dio nijednog efikasnog portfelja. Najrizičniji efikasni portfelj je ulaganje cjelokupnog iznosa u dionicu IEKG, što rezultira maksimalnim prinosom od 1,64% kod modela s donjom polu-varijancom kao mjerom rizika, dok je maksimalni prinos od 1,49% ostvaren kod modela koji primjenjuje varijancu kao mjeru rizika.

Na srbijanskom tržištu kapitala najzastupljenije dionice koje u efikasnim portfeljima dobivenim primjenom varijance su ALFA, IMPL i NIIS. Najzastupljenije dionice u efikasnim portfeljima dobivenim primjenom donje polu-varijance su dionice ENHL, IMPL i TGAS. Na srbijanskom tržištu kapitala također povećavanjem rizika manji broj dionica sačinjava efikasni portfelj dobiven primjenom donje polu-varijance nego li je to slučaj kod efikasnih portfelja dobivenih primjenom varijance. Tako na primjer dionica SJPT ulazi u sastav samo najmanje rizičnog efikasnog portfelja kod modela s donjom polu-varijancom, a kod modela s varijancom ista dionica ulazi u sastav svih portfelja osim najrizičnijeg. Najrizičniji efikasni portfelj s maksimalnim prinosom od 1,44% je ulaganje cjelokupnog iznosa u dionicu IMPL, što je postignuto kod oba modela korištenjem različite mjere rizika.

6. ZAKLJUČAK

Osnovna ideja Markowitzevog modela optimizacije portfelja bila je naći ravnotežu između rizika (mjereno varijansom) i očekivanog prinosa portfelja, tj. pronaći efikasan portfelj. Takav portfelj za zadanu stopu rizika ima najveću stopu prinosa, odnosno za zadanu stopu prinosa ima minimalan rizik. Markowitzev mean-variance model često je kritiziran zbog neispunjavanja pretpostavki koje zahtjeva. Istraživanja provedena na različitim tržištima kapitala pokazala su kako je u praksi najzastupljeniji asimetričan oblik distribucije prinosa sa debelim repovima. U takvim slučajevima varijanca nije adekvatna mjera rizika, te je prikladnija primjena nekog od modela sa donjim parcijalnim mjerama rizika. Alternativna mjera rizika koja je korištena u ovom radu je donja polu-varijanca. Prednost donje polu-varijance nad varijansom, na koju je ukazao i sam Markowitz, je u tome što se u promatranje uzimaju samo oni prinosi koji su manji od očekivanog prinosa, te se za njih računa prosječno kvadratno odstupanje. Ukoliko su prinosi normalno distribuirani, upotreba donje polu-varijance kao mjere rizika nije potrebna jer je ona u tom slučaju jednaka varijanci.

U ovom radu ispitana je primjenjivost modela s donjom polu-varijansom kao mjerom rizika na hrvatskom, slovenskom i srbijanskom tržištu kapitala. Pomoćna hipoteza „*Prinosi dionica na regionalnim tržištima kapitala nisu normalno distribuirani*“ se prihvaća jer je statističkim testovima utvrđeno kako tjedni prinosi većine dionica na promatranim tržištima u promatranom vremenskom razdoblju nisu normalnog oblika. Asimetričnost distribucija prinosa dionica ukazuje na neispunjenje pretpostavki Markowitzeva modela i neadekvatnost primjene varijance, te opravdava primjenu donje polu-varijance kao alternativne mjere rizika. Hrvatsko, slovensko i srbijansko tržište kapitala predstavljaju tržišta u nastajanju za koja je karakteristična plitkost i nelikvidnost tržišta, nedostatak tržišta transparentnosti, visoki transakcijski troškovi, nekompatibilnost računovodstvenih standarda s međunarodnim standardima i slabo korporativno upravljanje. Navedene karakteristike regionalnih tržišta navode nas na primjenu donje polu-varijance kao mjere rizika.

Odnos efikasnih granica izračunatih primjenom varijance i efikasnih granica izračunatih primjenom donje polu-varijance je vrlo sličan. Kod oba modela slovensko tržište kapitala ima najveći raspon rizika, a najmanji raspon rizika je na srbijanskom tržištu kapitala. Također sličan

odnos efikasnih granica je kod oba modela pri niskim i visokim razinama rizika. Kod oba modela na vrlo niskim razinama rizika portfelji oblikovani na slovenskom tržištu kapitala pružaju najbolje rezultate, dok su najlošiji rezultati na srbijanskom tržištu kapitala. Pri višim razinama rizika kod obaju modela srbijansko tržište ima najbolji omjer prinosa i rizika, ali kod MV modela najbolji rezultat je na slovenskom tržištu kapitala, dok je najlošiji rezultat kod primjene donje polu-varijance postignut na hrvatskom tržištu kapitala. Razlike između dviju mjera rizika uočavaju se pri srednjim razinama rizika. Kod efikasnih portfelja dobivenih primjenom varijance pri srednjim razinama rizika, hrvatsko tržište ima najbolji omjer prinosa i rizika, dok kod efikasnih portfelja dobivenih primjenom donje polu-varijance rizika slovensko tržište ima najbolji omjer prinosa i rizika. Veće razlike između dvaju modela vidljive su u sastavima efikasnih portfelja. Tako na primjer na hrvatskom tržištu kapitala dionica ATGR ulazi u sastav samo najmanje rizičnog portfelja kod modela s donjom polu-varijancom, a kod modela s varijancom ista dionica ulazi u sastav svih portfelja osim najrizičnijeg. Na slovenskom tržištu kapitala dionica KRKG ulazi u sastav tri efikasna portfelja kod modela s donjom polu-varijancom, a kod modela s varijancom ista dionica ulazi u sastav svih efikasnih portfelja osim najrizičnijeg. Na srbijanskom tržištu kapitala dionica SJPT ulazi u sastav samo najmanje rizičnog efikasnog portfelja kod modela s donjom polu-varijancom, a kod modela s varijancom ista dionica ulazi u sastav svih efikasnih portfelja osim najrizičnijeg. Navedeno upućuje na zaključak da donja polu-varijanica nosi različite rezultate od varijance u pogledu sastava efikasnog portfelja u ovisnosti o razini rizika i prinosa. Na hrvatskom i slovenskom tržištu dionice ZABA i POSR nisu ušle u sastav nijednog efikasnog portfelja izračunatog primjenom varijance, kao ni u sastav nijednog efikasnog portfelja izračunatog primjenom donje polu-varijance. Na svim analiziranim tržištima ista dionica koja jedina oblikuje najrizičniji efikasni portfelj izračunat primjenom varijance, jedina oblikuje i najrizičniji efikasni portfelj izračunat primjenom donje polu-varijance. Na primjer, investitor sklon riziku koji preferira maksimalni prinos će na sva tri tržišta uložiti određeni iznos u jednu te istu dionicu neovisno o mjeri rizika koju primjenjuje. Na hrvatskom i srbijanskom tržištu investitor će ostvariti i jednak prinos, dok na slovenskom tržištu kapitala ulaganjem u najrizičniji efikasni portfelj gdje je cjelokupan iznos uložen u dionicu IEKG, veći prinos će biti ostvaren kod modela s donjom polu-varijancom kao mjerom rizika. S obzirom na utvrđenu asimetričnost distribucija prinosa dionica, različite odnose efikasnih granica i različite sastave efikasnih portfelja u dvama istraživanim modelima optimizacije može se prihvatiti radna

istraživačka hipoteza „*S obzirom na karakteristike regionalnih tržišta kapitala donja polu-varijanca prikladnija je mjera rizika od varijance*“ uz napomene kako bi stvarnim ulaganjem na hrvatskom, slovenskom i srbijanskom tržištu u određenom vremenskom periodu mogli pouzdano potvrditi prednost korištenja donje polu-varijance nad varijancom. Na kraju odabir efikasnog portfelja, ovisit će o investitorovoj funkciji korisnosti, odnosno prinosu kojeg investitor zahtjeva i njegovoj sklonosti riziku.

LITERATURA

1. Aljinović, Z., Marasović, B., Tomić-Plazibat, N., (2005): An Application of MATHLAB and Excel in Financial Modeling, Computers in education, Proceedings of the 28th International Convention, MIPRO, Opatija, Croatia, str. 120.-125.
2. Aljinović, Z., Marasović, B., Šego, B., (2011): Financijsko modeliranje, II. Izmijenjeno i dopunjeno izdanje, Sveučilište u Splitu, Ekonomski fakultet, Split
3. Aljinović, Z., (2016): Od varijance prema alternativnim mjerama rizika u Modernoj portfolio teoriji (MPT), nastavni materijali, Ekonomski fakultet, Beograd
4. Aljinović, Z., Marasović, B., Vidović, J., (2010): The alternative risk measures in Excel, Proceedings of the 33rd International Convention, MIPRO, Opatija, Croatia, str. 908.-913.
5. Aljinović, Z., Marasović, B., Pivac, S., (2007): Transition Capital Markets Comparison by Efficient Frontiers, Seventh International Conference on „Enterprise in Transition“, Faculty of Economics, Split, Split-Bol, Croatia, str. 939.-948.
6. Benić, V., Franić, I., (2008): Komparativna analiza likvidnosti tržišta kapitala Hrvatske i zemalja regije, Financijska teorija i praksa, Vol. 32, No. 4, str. 481.-502.
7. Boasson, V., Boasson, E., Zhou, Z., (2011): Portfolio Optimization in a Mean-semivariance Framework, Investment Management and Financial Innovations, Volume 8, Issue 3, 58.- 68.
8. Jakšić, S., (2007): Primjena Markowitzove teorije na tržište dionica Zagrebačke burze, Zbornik Ekonomskog fakulteta u Zagrebu, Vol. 5, No. 1, str. 331.-344.
9. Kapor, P., (2012): Tržište kapitala u Srbiji, Megatrend Review, Vol. 9, No. 4, str. 47.-68.
10. Konno, H., Waki, H., Yukki, A., (2002): Portfolio Optimization Under Lower Partial Risk Measures, Asia-Pacific Financial Markets, Volume 9, Issue 2, str. 127.-140.
11. Latković, M., Barac, Z., (1999): Optimizacija dioničkih portfelja na rubnim tržištima kapitala, preprint, Sveučilište u Zagrebu, Zagreb
12. Marasović, B., Šego, B., (2006): Izbor optimalnog portfelja alternativnim mjerama rizika, Računovodstvo i financije, 52(2006), 7, str. 66.-71.

13. Marasović, B., (2006): Modeli optimizacije investicijskog portfelja, magistarski rad, Sveučilište u Zagrebu, Ekonomski fakultet, Split
14. Marasović, B., (2016): Model za rebalans portfelja s uključenim transakcijskim troškovima i donjom poluapsolutnom devijacijom kao mjerom rizika, Ekonomska misao i praksa, No. 2, str. 515.-534.
15. Mirjanić, B.,(2015): Upravljanje performansama akcijskog portfolia u specifičnim uslovima novonastajućih finansijskih tržišta: Primjer Beogradske berze, doktorska disertacija, Fakultet za poslovno industrijski menadžment, Beograd
16. Pivac, S., (2010): Statističke metode, Ekonomski fakultet, Split
17. Prokopijević, N., (2006): Tržište kapitala u Srbiji, Bilten Beogradske berze, god. 11, br. 123/2006, str. 6.-9.
18. Simonetti, M., (2010): Razvojne prilike trga kapitala v Sloveniji po finančni krizi, Institute for Economic Research, Ljubljana
19. Stanivuk, T., (2009): Mogućnosti i ograničenja primjene Markowitzove teorije portfelja na hrvatskom tržištu kapitala, magistarski rad, Sveučilište u Splitu, Ekonomski fakultet, Split
20. Tomić-Plazibat, N., Aljinović, Z., Marasović, B., (2006): Matematički modeli u finansijskom upravljanju, Sveučilište u Splitu, Ekonomski fakultet, Split
21. Zagrebačka burza (2017): Pregled trgovine u 2016. godini, Zagrebačka burza d.d., Zagreb
22. Zelenika, R., (2000): Metodologija i tehnologija izrade znanstvenog i stručnog djela, četvrto izdanje, Ekonomski fakultet u Rijeci, Rijeka

Internetski izvori:

1. <http://www.belex.rs/>
2. <https://hrcak.srce.hr/>
3. <http://www.ljse.si/>
4. <http://www.zse.hr/>

PRILOZI

Prilog 1: Tjedne cijene zatvaranja odabranih dionica sa Zagrebačke burze

datum	CROBEX	ADPL	ADRS2	ATGR	ATPL	ERNT	HT	KOEI	PODR	RIVP	ZABA
1.1.2016	1689,63	97,84	364,73	828,02	137,83	1035,78	143,68	654,92	336,78	23,92	36,34
8.1.2016	1635,94	95,00	361,18	822,21	129,20	1000,20	140,56	650,10	329,90	23,84	36,52
15.1.2016	1588,18	96,73	349,57	812,72	118,90	990,72	137,84	630,01	311,93	23,34	35,64
22.1.2016	1604,20	95,34	347,35	809,12	119,40	983,01	139,39	637,00	313,89	22,83	36,75
29.1.2016	1612,19	93,12	345,00	814,01	117,75	991,53	139,61	647,99	318,97	22,91	37,23
5.2.2016	1603,52	96,33	342,04	810,11	109,22	971,61	140,89	647,00	314,59	22,82	37,94
12.2.2016	1592,84	94,53	341,00	805,36	100,00	942,43	140,35	631,14	313,38	22,95	37,88
19.2.2016	1621,21	97,01	362,16	809,00	104,86	994,78	145,94	640,55	315,19	22,91	38,34
26.2.2016	1613,22	101,35	358,51	809,27	99,01	998,01	141,27	636,84	316,02	23,12	38,98
4.3.2016	1599,71	101,91	353,33	805,00	107,98	992,20	140,89	637,56	311,04	23,49	39,49
11.3.2016	1613,45	101,00	355,03	810,02	115,49	1015,94	142,64	635,42	309,94	23,88	39,23
18.3.2016	1630,32	99,00	364,57	800,16	103,45	1040,11	142,68	648,74	319,80	24,32	39,48
25.3.2016	1661,51	101,20	380,50	804,90	110,47	1108,23	143,77	640,00	324,43	24,62	39,86
1.4.2016	1671,08	102,37	390,01	823,03	115,74	1100,57	145,41	645,89	320,53	24,54	41,47
8.4.2016	1661,17	102,32	390,17	815,55	108,08	1091,94	146,53	631,53	320,21	24,58	39,64
15.4.2016	1686,10	99,40	397,00	817,15	117,55	1089,75	146,22	642,43	327,72	24,67	41,64
22.4.2016	1693,14	97,89	397,75	814,76	119,21	1079,26	147,74	655,00	330,04	24,62	41,00
29.4.2016	1688,48	99,98	394,94	815,00	126,90	1081,87	143,89	645,00	328,86	24,49	41,76
6.5.2016	1686,40	97,12	391,71	815,01	120,00	1116,57	139,17	649,98	340,17	24,05	40,70
13.5.2016	1698,76	97,17	392,33	827,51	122,41	1118,26	140,03	669,51	340,65	24,06	40,72
20.5.2016	1698,16	99,61	392,77	815,91	132,42	1122,40	139,90	669,05	342,94	23,84	40,00
27.5.2016	1721,49	105,98	394,00	815,00	134,26	1122,66	140,30	683,61	347,73	24,00	40,50
3.6.2016	1704,14	114,62	387,50	815,25	129,06	1012,35	141,17	686,13	341,71	24,01	40,87
10.6.2016	1694,96	111,25	399,20	818,49	130,65	1004,35	140,72	670,00	343,00	23,98	39,35

17.6.2016	1678,85	112,95	387,53	815,41	136,31	1008,01	140,82	667,07	339,56	23,98	39,01
24.6.2016	1653,32	109,08	387,73	793,83	132,19	1001,02	139,26	650,00	325,18	23,93	39,43
1.7.2016	1679,48	112,33	377,95	814,74	136,68	1004,95	141,63	636,85	330,22	24,77	39,08
8.7.2016	1723,79	122,54	381,82	814,37	146,68	1020,40	142,76	675,00	342,80	25,05	39,02
15.7.2016	1724,23	119,66	383,87	824,09	174,42	1006,38	142,79	662,68	333,99	24,76	39,84
22.7.2016	1749,83	114,52	393,46	818,85	195,00	1003,96	142,85	675,77	335,71	25,45	40,55
29.7.2016	1773,97	111,65	408,49	816,14	181,16	1009,09	143,18	663,00	359,00	26,66	41,26
5.8.2016	1770,25	112,52	402,19	814,20	172,15	1010,47	142,45	656,87	356,00	26,88	41,01
12.8.2016	1786,31	115,36	401,22	814,03	184,14	1016,31	142,24	658,06	359,76	27,22	42,26
19.8.2016	1792,81	118,01	404,26	816,58	185,00	1016,91	143,43	657,90	360,35	29,33	41,85
26.8.2016	1808,54	119,00	406,95	819,16	182,37	1030,85	145,53	669,89	365,79	29,00	42,08
2.9.2016	1823,65	123,83	405,46	821,98	173,31	1095,75	154,59	674,90	356,97	28,78	41,07
9.9.2016	1851,17	128,17	415,90	844,11	193,60	1127,12	156,19	673,00	360,34	28,85	40,57
16.9.2016	1875,90	126,42	417,93	847,00	176,11	1163,74	161,10	662,23	361,06	30,32	44,77
23.9.2016	1937,17	131,19	435,66	871,03	193,57	1138,20	164,87	673,67	383,84	32,84	49,17
30.9.2016	1941,32	136,88	436,19	868,62	180,03	1142,00	163,60	676,38	379,00	34,15	48,83
7.10.2016	1992,03	140,01	480,19	879,01	196,71	1149,09	165,17	690,27	381,00	34,48	51,74
14.10.2016	1972,42	140,04	459,15	869,94	240,84	1149,67	161,81	682,76	374,20	35,00	50,55
21.10.2016	1959,68	140,01	449,74	866,03	281,90	1152,58	159,93	683,20	371,60	32,98	50,05
28.10.2016	1964,41	139,86	450,00	865,04	295,17	1144,50	164,23	678,75	369,60	32,55	50,99
4.11.2016	1946,98	138,80	454,45	873,07	301,31	1124,34	166,07	670,91	370,37	31,47	48,91
11.11.2016	1962,86	137,49	451,55	882,41	342,26	1115,05	162,71	683,79	367,43	31,78	48,82
18.11.2016	1978,63	137,64	451,78	883,31	367,92	1102,00	162,30	682,03	379,87	33,89	49,00
25.11.2016	1992,49	139,88	457,47	891,00	351,04	1129,66	163,24	691,67	381,85	34,53	50,97
2.12.2016	1986,33	138,19	459,57	874,90	329,35	1145,92	167,09	680,03	380,44	34,07	51,60
9.12.2016	1982,98	135,67	456,57	869,69	321,24	1140,31	171,14	682,00	375,51	34,33	52,77
16.12.2016	1968,33	134,09	453,02	867,05	283,93	1144,47	171,86	680,00	374,58	33,90	50,70
23.12.2016	1991,43	135,62	457,78	870,02	282,83	1153,33	175,50	690,39	378,78	33,98	53,90
30.12.2016	1994,84	138,61	456,30	884,12	282,55	1163,99	169,03	690,00	379,22	34,59	54,00
6.1.2017	2030,28	138,02	460,00	881,36	282,16	1187,80	167,64	703,41	382,61	36,22	57,28
13.1.2017	2075,95	139,46	466,81	910,00	291,71	1240,26	173,17	710,00	380,15	38,92	59,96
20.1.2017	2096,56	139,80	469,74	931,38	307,72	1257,54	173,38	755,49	381,10	38,56	59,19

27.1.2017	2108,89	141,98	470,02	922,00	336,52	1247,43	172,65	777,87	394,36	39,03	58,96
3.2.2017	2170,28	146,99	487,60	929,81	334,01	1292,87	173,71	824,83	413,90	41,95	60,56
10.2.2017	2163,03	152,97	496,25	943,59	329,27	1320,24	174,47	799,43	412,85	41,55	62,53
17.2.2017	2192,75	152,45	497,63	943,83	329,90	1342,56	179,11	819,54	409,05	42,11	62,60
24.2.2017	2243,46	158,17	511,37	984,26	312,95	1424,46	189,50	856,06	418,67	42,07	64,63
3.3.2017	2218,38	162,88	505,57	909,08	324,46	1406,97	187,06	849,90	407,91	42,54	66,20
10.3.2017	2225,09	164,24	499,76	916,32	377,44	1407,05	185,12	849,29	403,17	41,99	66,72
17.3.2017	2177,24	164,77	493,07	901,05	382,65	1402,35	179,90	829,94	390,29	43,91	64,88
24.3.2017	2112,83	160,01	488,71	881,34	388,54	1408,65	174,11	799,99	365,24	42,78	64,77
31.3.2017	1989,27	156,89	461,75	784,12	408,94	1358,22	172,63	787,62	351,38	42,29	59,45
7.4.2017	1950,41	157,57	457,72	795,29	432,33	1371,93	173,70	786,68	349,27	42,04	59,31
14.4.2017	1905,29	157,90	452,78	790,62	465,25	1368,88	175,28	752,53	350,01	42,19	57,38
21.4.2017	1949,21	159,00	469,68	819,97	430,56	1341,92	174,36	767,70	367,43	42,48	58,91
28.4.2017	1901,87	163,75	457,32	794,93	417,59	1313,70	178,44	799,10	348,57	41,92	48,62
5.5.2017	1904,50	165,64	457,20	780,02	406,23	1343,78	176,38	799,90	346,23	41,94	48,70
12.5.2017	1885,17	171,49	469,98	780,07	400,63	1320,92	172,06	801,54	347,00	40,56	48,55
19.5.2017	1861,19	170,47	462,75	771,59	370,04	1306,62	168,52	788,48	340,16	40,26	46,40
26.5.2017	1862,07	172,31	460,05	750,97	383,56	1302,62	168,19	793,38	339,61	40,03	46,98
2.6.2017	1853,31	166,64	474,62	758,56	380,08	1292,36	173,42	757,30	320,61	41,34	46,03
9.6.2017	1839,81	168,87	456,66	754,49	399,60	1178,38	174,42	741,27	311,22	41,81	44,85
16.6.2017	1857,87	167,46	464,93	770,00	381,72	1243,36	177,42	726,14	316,22	43,56	45,59
23.6.2017	1864,58	169,28	471,83	775,04	389,92	1229,27	175,57	725,52	324,66	43,12	46,68
30.6.2017	1865,57	166,15	464,96	770,40	397,65	1245,72	181,91	730,05	323,61	43,85	46,70

Prilog 2: Tjedni prinosi odabranih dionica sa Zagrebačke burze

datum	CROBEX	ADPL	ADRS2	ATGR	ATPL	ERNT	HT	KOEI	PODR	RIVP	ZABA
1.1.2016											
8.1.2016	-0,03229	-0,02946	-0,00978	-0,00704	-0,06466	-0,03495	-0,02195	-0,00739	-0,02064	-0,00335	0,00494
15.1.2016	-0,02963	0,01805	-0,03267	-0,01161	-0,08308	-0,00952	-0,01954	-0,03139	-0,05601	-0,02120	-0,02439
22.1.2016	0,01004	-0,01447	-0,00637	-0,00444	0,00420	-0,00781	0,01118	0,01103	0,00626	-0,02209	0,03067
29.1.2016	0,00497	-0,02356	-0,00679	0,00603	-0,01392	0,00863	0,00158	0,01711	0,01605	0,00350	0,01298
5.2.2016	-0,00539	0,03389	-0,00862	-0,00480	-0,07520	-0,02029	0,00913	-0,00153	-0,01383	-0,00394	0,01889
12.2.2016	-0,00668	-0,01886	-0,00305	-0,00588	-0,08819	-0,03049	-0,00384	-0,02482	-0,00385	0,00568	-0,00158
19.2.2016	0,01765	0,02590	0,06020	0,00451	0,04746	0,05406	0,03906	0,01480	0,00576	-0,00174	0,01207
26.2.2016	-0,00494	0,04377	-0,01013	0,00033	-0,05741	0,00324	-0,03252	-0,00581	0,00263	0,00912	0,01655
4.3.2016	-0,00841	0,00551	-0,01455	-0,00529	0,08673	-0,00584	-0,00269	0,00113	-0,01588	0,01588	0,01300
11.3.2016	0,00855	-0,00897	0,00480	0,00622	0,06724	0,02364	0,01234	-0,00336	-0,00354	0,01647	-0,00661
18.3.2016	0,01040	-0,02000	0,02652	-0,01225	-0,11010	0,02351	0,00028	0,02075	0,03132	0,01826	0,00635
25.3.2016	0,01895	0,02198	0,04277	0,00591	0,06566	0,06344	0,00761	-0,01356	0,01437	0,01226	0,00958
1.4.2016	0,00574	0,01149	0,02469	0,02227	0,04660	-0,00694	0,01134	0,00916	-0,01209	-0,00325	0,03960
8.4.2016	-0,00595	-0,00049	0,00041	-0,00913	-0,06847	-0,00787	0,00767	-0,02248	-0,00100	0,00163	-0,04513
15.4.2016	0,01490	-0,02895	0,01735	0,00196	0,08399	-0,00201	-0,00212	0,01711	0,02318	0,00365	0,04922
22.4.2016	0,00417	-0,01531	0,00189	-0,00293	0,01402	-0,00967	0,01034	0,01938	0,00705	-0,00203	-0,01549
29.4.2016	-0,00276	0,02113	-0,00709	0,00029	0,06251	0,00242	-0,02640	-0,01538	-0,00358	-0,00529	0,01837
6.5.2016	-0,00123	-0,02902	-0,00821	0,00001	-0,05591	0,03157	-0,03335	0,00769	0,03381	-0,01813	-0,02571
13.5.2016	0,00730	0,00051	0,00158	0,01522	0,01988	0,00151	0,00616	0,02960	0,00141	0,00042	0,00049
20.5.2016	-0,00035	0,02480	0,00112	-0,01412	0,07860	0,00370	-0,00093	-0,00069	0,00670	-0,00919	-0,01784
27.5.2016	0,01364	0,06199	0,00313	-0,00112	0,01380	0,00023	0,00286	0,02153	0,01387	0,00669	0,01242
3.6.2016	-0,01013	0,07837	-0,01664	0,00031	-0,03950	-0,10343	0,00618	0,00368	-0,01746	0,00042	0,00909
10.6.2016	-0,00540	-0,02984	0,02975	0,00397	0,01224	-0,00793	-0,00319	-0,02379	0,00377	-0,00125	-0,03790
17.6.2016	-0,00955	0,01517	-0,02967	-0,00377	0,04241	0,00364	0,00071	-0,00438	-0,01008	0,00000	-0,00868
24.6.2016	-0,01532	-0,03486	0,00052	-0,02682	-0,03069	-0,00696	-0,01114	-0,02592	-0,04327	-0,00209	0,01071

1.7.2016	0,01570	0,02936	-0,02555	0,02600	0,03340	0,00392	0,01688	-0,02044	0,01538	0,03450	-0,00892
8.7.2016	0,02604	0,08700	0,01019	-0,00045	0,07061	0,01526	0,00795	0,05818	0,03739	0,01124	-0,00154
15.7.2016	0,00026	-0,02378	0,00535	0,01186	0,17321	-0,01383	0,00021	-0,01842	-0,02604	-0,01164	0,02080
22.7.2016	0,01474	-0,04390	0,02468	-0,00638	0,11153	-0,00241	0,00042	0,01956	0,00514	0,02749	0,01766
29.7.2016	0,01370	-0,02538	0,03749	-0,00332	-0,07362	0,00510	0,00231	-0,01908	0,06707	0,04645	0,01736
5.8.2016	-0,00210	0,00776	-0,01554	-0,00238	-0,05101	0,00137	-0,00511	-0,00929	-0,00839	0,00822	-0,00608
12.8.2016	0,00903	0,02493	-0,00241	-0,00021	0,06733	0,00576	-0,00148	0,00181	0,01051	0,01257	0,03003
19.8.2016	0,00363	0,02271	0,00755	0,00313	0,00466	0,00059	0,00833	-0,00024	0,00164	0,07466	-0,00975
26.8.2016	0,00874	0,00835	0,00663	0,00315	-0,01432	0,01362	0,01454	0,01806	0,01498	-0,01132	0,00548
2.9.2016	0,00832	0,03979	-0,00367	0,00344	-0,05096	0,06106	0,06039	0,00745	-0,02441	-0,00762	-0,02429
9.9.2016	0,01498	0,03445	0,02542	0,02657	0,11071	0,02823	0,01030	-0,00282	0,00940	0,00243	-0,01225
16.9.2016	0,01327	-0,01375	0,00487	0,00342	-0,09469	0,03197	0,03095	-0,01613	0,00200	0,04970	0,09851
23.9.2016	0,03214	0,03704	0,04155	0,02798	0,09453	-0,02219	0,02313	0,01713	0,06118	0,07984	0,09375
30.9.2016	0,00214	0,04246	0,00122	-0,00277	-0,07252	0,00333	-0,00773	0,00401	-0,01269	0,03912	-0,00694
7.10.2016	0,02579	0,02261	0,09610	0,01189	0,08861	0,00619	0,00955	0,02033	0,00526	0,00962	0,05789
14.10.2016	-0,00989	0,00021	-0,04480	-0,01037	0,20240	0,00050	-0,02055	-0,01094	-0,01801	0,01497	-0,02327
21.10.2016	-0,00648	-0,00021	-0,02071	-0,00450	0,15742	0,00253	-0,01169	0,00064	-0,00697	-0,05945	-0,00994
28.10.2016	0,00241	-0,00107	0,00058	-0,00114	0,04600	-0,00704	0,02653	-0,00653	-0,00540	-0,01312	0,01861
4.11.2016	-0,00891	-0,00761	0,00984	0,00924	0,02059	-0,01777	0,01114	-0,01162	0,00208	-0,03374	-0,04165
11.11.2016	0,00812	-0,00948	-0,00640	0,01064	0,12743	-0,00830	-0,02044	0,01902	-0,00797	0,00980	-0,00184
18.11.2016	0,00800	0,00109	0,00051	0,00102	0,07229	-0,01177	-0,00252	-0,00258	0,03330	0,06428	0,00368
25.11.2016	0,00698	0,01614	0,01252	0,00867	-0,04697	0,02479	0,00578	0,01404	0,00520	0,01871	0,03942
2.12.2016	-0,00310	-0,01216	0,00458	-0,01823	-0,06378	0,01429	0,02331	-0,01697	-0,00370	-0,01341	0,01228
9.12.2016	-0,00169	-0,01840	-0,00655	-0,00597	-0,02493	-0,00491	0,02395	0,00289	-0,01304	0,00760	0,02242
16.12.2016	-0,00742	-0,01171	-0,00781	-0,00304	-0,12346	0,00364	0,00420	-0,00294	-0,00248	-0,01260	-0,04002
23.12.2016	0,01167	0,01135	0,01045	0,00342	-0,00388	0,00771	0,02096	0,01516	0,01115	0,00236	0,06120
30.12.2016	0,00171	0,02181	-0,00324	0,01608	-0,00099	0,00920	-0,03756	-0,00057	0,00116	0,01779	0,00185
6.1.2017	0,01761	-0,00427	0,00808	-0,00313	-0,00138	0,02025	-0,00826	0,01925	0,00890	0,04605	0,05897
13.1.2017	0,02225	0,01038	0,01470	0,03198	0,03329	0,04322	0,03245	0,00933	-0,00645	0,07190	0,04573
20.1.2017	0,00988	0,00244	0,00626	0,02322	0,05343	0,01384	0,00121	0,06210	0,00250	-0,00929	-0,01293
27.1.2017	0,00586	0,01547	0,00060	-0,01012	0,08947	-0,00807	-0,00422	0,02919	0,03420	0,01212	-0,00389
3.2.2017	0,02869	0,03468	0,03672	0,00844	-0,00749	0,03578	0,00612	0,05862	0,04836	0,07215	0,02678

10.2.2017	-0,00335	0,03988	0,01758	0,01471	-0,01429	0,02095	0,00437	-0,03128	-0,00254	-0,00958	0,03201
17.2.2017	0,01365	-0,00341	0,00278	0,00025	0,00191	0,01676	0,02625	0,02484	-0,00925	0,01339	0,00112
24.2.2017	0,02286	0,03683	0,02724	0,04194	-0,05275	0,05921	0,05639	0,04360	0,02325	-0,00095	0,03191
3.3.2017	-0,01124	0,02934	-0,01141	-0,07946	0,03612	-0,01235	-0,01296	-0,00722	-0,02604	0,01111	0,02400
10.3.2017	0,00302	0,00832	-0,01156	0,00793	0,15125	0,00006	-0,01043	-0,00072	-0,01169	-0,01301	0,00782
17.3.2017	-0,02174	0,00322	-0,01348	-0,01680	0,01371	-0,00335	-0,02860	-0,02305	-0,03247	0,04471	-0,02797
24.3.2017	-0,03003	-0,02931	-0,00888	-0,02212	0,01528	0,00448	-0,03271	-0,03675	-0,06634	-0,02607	-0,00170
31.3.2017	-0,06026	-0,01969	-0,05675	-0,11688	0,05117	-0,03646	-0,00854	-0,01558	-0,03869	-0,01152	-0,08571
7.4.2017	-0,01973	0,00432	-0,00877	0,01414	0,05562	0,01004	0,00618	-0,00119	-0,00602	-0,00593	-0,00236
14.4.2017	-0,02341	0,00209	-0,01085	-0,00589	0,07339	-0,00223	0,00906	-0,04438	0,00212	0,00356	-0,03308
21.4.2017	0,02279	0,00694	0,03665	0,03645	-0,07749	-0,01989	-0,00526	0,01996	0,04857	0,00685	0,02632
28.4.2017	-0,02459	0,02944	-0,02667	-0,03101	-0,03059	-0,02125	0,02313	0,04009	-0,05269	-0,01327	-0,19198
5.5.2017	0,00138	0,01148	-0,00026	-0,01893	-0,02758	0,02264	-0,01161	0,00100	-0,00674	0,00048	0,00164
12.5.2017	-0,01020	0,03471	0,02757	0,00006	-0,01388	-0,01716	-0,02480	0,00205	0,00222	-0,03346	-0,00308
19.5.2017	-0,01280	-0,00597	-0,01550	-0,01093	-0,07943	-0,01088	-0,02079	-0,01643	-0,01991	-0,00742	-0,04529
26.5.2017	0,00047	0,01074	-0,00585	-0,02709	0,03588	-0,00307	-0,00196	0,00620	-0,00162	-0,00573	0,01242
2.6.2017	-0,00472	-0,03346	0,03118	0,01006	-0,00911	-0,00791	0,03062	-0,04654	-0,05757	0,03220	-0,02043
9.6.2017	-0,00731	0,01329	-0,03858	-0,00538	0,05008	-0,09233	0,00575	-0,02139	-0,02973	0,01130	-0,02597
16.6.2017	0,00977	-0,00838	0,01795	0,02035	-0,04578	0,05368	0,01705	-0,02062	0,01594	0,04100	0,01636
23.6.2017	0,00361	0,01081	0,01473	0,00652	0,02125	-0,01140	-0,01048	-0,00085	0,02634	-0,01015	0,02363
30.6.2017	0,00053	-0,01866	-0,01467	-0,00600	0,01963	0,01329	0,03547	0,00622	-0,00324	0,01679	0,00043

Prilog 3: Tjedne cijene zatvaranja odabranih dionica sa Ljubljanske burze

datum	SBITOP	CICG	GRVG	IEKG	KRKG	LKPG	PETG	POSR	TLSG	UKIG	ZVTG
1.1.2016	696,15	76,00	4,60	0,53	65,20	23,00	255,80	12,95	73,01	11,15	23,50
8.1.2016	681,03	76,00	4,50	0,55	62,30	22,25	249,00	12,63	73,95	11,12	24,00
15.1.2016	670,11	76,00	4,40	0,68	60,69	21,45	250,00	12,20	73,19	11,25	23,70
22.1.2016	675,80	75,00	4,48	0,56	60,80	22,49	255,00	12,01	72,50	10,80	23,85
29.1.2016	688,77	73,90	4,50	0,62	62,00	22,98	260,00	12,89	72,50	11,00	24,00
5.2.2016	680,16	73,40	4,46	0,55	61,15	22,39	256,05	12,50	73,50	11,00	23,75
12.2.2016	667,60	71,98	4,30	0,60	60,50	20,72	259,10	11,80	72,21	11,10	22,90
19.2.2016	674,56	71,00	4,28	0,54	60,55	21,00	262,00	11,94	72,51	11,08	23,80
26.2.2016	685,36	71,20	4,40	0,51	61,50	21,15	267,30	12,50	73,49	10,56	23,66
4.3.2016	694,58	74,00	4,39	0,55	61,00	21,74	272,00	12,49	75,50	11,50	24,80
11.3.2016	711,87	79,00	4,32	0,58	61,35	23,00	274,80	13,70	77,50	11,40	26,01
18.3.2016	714,35	80,00	4,22	0,51	60,90	23,63	277,00	14,01	79,01	11,00	25,68
25.3.2016	719,69	82,50	4,40	0,51	61,10	23,35	276,50	14,30	79,00	11,00	26,55
1.4.2016	722,30	82,50	4,37	0,54	60,91	23,10	279,55	14,50	78,51	10,90	27,00
8.4.2016	722,84	82,00	4,42	0,55	61,00	22,90	283,00	14,10	77,00	10,99	27,35
15.4.2016	715,77	80,00	4,70	0,53	60,85	23,00	271,50	14,55	76,40	10,60	26,75
22.4.2016	718,27	78,02	4,80	0,53	60,82	22,75	275,65	14,51	75,00	11,01	27,11
29.4.2016	711,83	79,80	5,20	0,60	60,62	23,00	262,10	14,80	75,00	11,40	26,80
6.5.2016	714,26	80,10	5,20	0,52	60,50	22,60	265,10	14,60	77,00	11,90	26,92
13.5.2016	714,77	83,50	5,30	0,61	60,50	23,00	263,00	14,60	76,98	13,00	27,01
20.5.2016	707,72	82,00	5,95	0,55	59,05	23,00	263,00	14,50	73,00	14,00	26,48
27.5.2016	706,36	81,00	6,13	0,78	59,00	23,00	264,50	14,60	71,00	14,00	26,01
3.6.2016	694,46	81,90	6,18	0,75	59,50	23,00	262,10	14,30	70,50	14,50	23,13

10.6.2016	693,19	78,11	6,55	0,70	58,91	22,71	263,10	14,40	70,40	13,75	22,55
17.6.2016	680,78	78,50	6,42	0,90	57,52	22,16	256,10	14,40	70,00	13,00	22,45
24.6.2016	680,92	79,15	6,00	0,95	57,50	22,50	261,15	14,25	70,11	13,50	22,30
1.7.2016	687,49	78,05	6,25	0,95	58,00	22,80	263,10	14,24	70,50	15,50	22,51
8.7.2016	701,75	79,00	6,50	0,94	58,50	22,98	266,15	14,50	73,99	14,79	23,51
15.7.2016	700,84	85,00	6,65	0,84	56,00	22,25	280,00	14,60	73,00	14,80	23,45
22.7.2016	703,30	87,88	6,63	0,83	57,39	22,40	278,50	14,30	72,00	14,60	23,65
29.7.2016	719,61	86,00	7,70	0,80	59,50	22,90	278,00	14,36	72,00	14,70	23,80
5.8.2016	710,71	88,00	7,15	0,92	58,50	22,61	273,00	14,50	73,00	15,00	24,00
12.8.2016	715,34	86,00	7,30	0,94	58,31	22,69	275,60	14,75	72,50	15,80	24,50
19.8.2016	725,34	88,99	7,60	1,00	59,90	22,55	280,00	14,93	74,00	16,39	23,80
26.8.2016	734,29	89,99	7,80	1,09	59,55	22,99	290,50	15,00	73,50	16,50	24,09
2.9.2016	733,58	86,50	7,65	1,10	59,99	23,00	293,70	14,30	72,80	18,00	24,15
9.9.2016	737,30	84,90	8,30	1,20	59,89	22,75	294,95	14,20	72,60	18,00	24,14
16.9.2016	740,12	87,10	8,30	1,35	60,00	22,63	304,50	14,03	72,00	18,00	23,50
23.9.2016	744,56	93,80	8,45	1,26	59,71	23,25	312,80	14,06	71,00	18,00	23,09
30.9.2016	741,71	101,50	7,90	1,14	61,90	23,00	306,20	13,99	71,22	18,00	22,50
7.10.2016	737,38	101,50	7,87	1,15	59,56	23,00	313,55	13,92	71,41	18,51	22,40
14.10.2016	724,15	95,90	8,10	1,09	58,77	23,01	302,25	13,20	71,15	18,20	22,03
21.10.2016	739,71	101,00	9,10	1,04	58,65	23,10	314,00	13,02	71,15	18,90	22,60
28.10.2016	746,61	103,00	8,78	1,15	58,50	23,15	319,75	13,65	72,40	17,51	23,11
4.11.2016	740,18	102,00	8,79	1,15	58,00	23,10	317,00	13,30	71,50	17,50	23,00
11.11.2016	734,09	103,10	8,62	1,05	58,00	22,80	310,00	13,30	71,75	17,50	23,02
18.11.2016	711,37	127,40	6,00	1,04	56,01	23,00	317,00	13,37	70,50	18,35	22,50
25.11.2016	706,14	136,90	6,05	1,03	54,00	23,00	318,00	13,37	71,00	18,20	22,65
2.12.2016	693,01	135,30	5,90	1,15	51,12	22,81	316,00	13,28	70,01	19,00	22,68
9.12.2016	705,46	147,00	5,83	1,16	53,30	23,00	315,15	13,10	72,41	18,50	23,02
16.12.2016	710,45	161,90	5,85	1,20	52,86	24,40	317,10	13,15	72,00	17,50	23,21
23.12.2016	705,21	160,00	5,82	1,17	51,00	24,88	318,00	13,35	71,80	19,80	23,15
30.12.2016	717,59	162,00	6,00	1,18	52,90	25,00	325,00	13,22	71,10	19,50	23,20
6.1.2017	728,91	169,80	6,05	1,30	52,85	1,30	320,30	13,56	76,90	19,41	24,20
13.1.2017	735,81	172,00	6,50	1,28	52,31	1,28	322,05	14,22	78,00	19,60	24,28

20.1.2017	737,93	170,00	6,36	1,38	52,02	1,38	327,00	14,81	78,00	19,90	24,32
27.1.2017	744,36	173,00	6,30	1,39	52,40	1,39	329,00	15,00	81,00	19,80	24,52
3.2.2017	744,09	173,00	6,30	1,45	52,00	1,45	327,00	15,00	81,20	19,95	24,90
10.2.2017	755,49	183,50	6,30	1,53	51,01	1,53	331,95	16,30	82,00	19,80	26,40
17.2.2017	762,63	189,45	6,53	1,88	51,10	1,88	330,00	16,19	85,95	19,80	26,20
24.2.2017	774,52	191,60	6,60	1,78	51,50	1,78	340,95	16,80	86,60	19,56	26,52
3.3.2017	793,83	195,00	6,62	1,85	52,94	1,85	358,00	16,95	87,00	19,99	26,31
10.3.2017	793,37	187,15	7,05	1,70	52,56	1,70	356,00	16,40	85,79	19,85	26,80
17.3.2017	801,72	189,90	7,21	1,50	53,00	1,50	352,05	16,30	87,20	19,59	27,60
24.3.2017	791,71	180,95	7,19	1,52	53,00	1,52	347,50	16,30	86,00	19,00	27,10
31.3.2017	774,70	184,60	7,00	1,70	52,15	1,70	336,05	16,20	86,79	19,40	26,00
7.4.2017	779,43	180,10	6,55	1,61	53,10	1,61	340,00	16,08	86,00	19,60	26,60
14.4.2017	778,24	174,10	6,75	1,75	52,87	1,75	345,00	16,10	84,00	19,10	26,20
21.4.2017	773,44	175,00	6,60	1,75	52,10	1,75	346,00	15,65	83,70	19,30	26,52
28.4.2017	782,32	182,00	6,65	1,80	52,30	1,80	351,00	15,80	85,98	19,00	26,72
5.5.2017	777,11	179,00	6,55	1,71	51,60	1,71	355,00	15,55	84,20	18,70	27,00
12.5.2017	782,68	175,00	6,65	1,70	53,50	1,70	352,50	15,55	84,15	18,65	26,88
19.5.2017	784,68	191,00	6,60	1,75	53,00	1,75	355,20	15,60	82,70	18,16	27,03
26.5.2017	789,05	194,90	6,75	1,91	52,89	1,91	357,05	15,97	83,00	18,17	27,10
2.6.2017	790,97	190,00	6,45	1,94	53,01	1,94	360,00	16,00	82,80	18,50	27,35
9.6.2017	792,17	184,15	6,42	1,94	53,20	1,94	360,00	16,25	83,00	18,53	27,38
16.6.2017	784,23	183,00	6,35	1,92	53,53	1,92	361,20	15,16	84,55	17,90	24,91
23.6.2017	792,22	170,15	6,30	1,95	54,50	1,95	373,00	15,50	83,20	18,50	24,96
30.6.2017	796,40	167,50	6,30	1,91	55,00	1,91	375,00	15,11	85,00	18,05	25,00

Prilog 4: Tjedni prinosi odabranih dionica sa Ljubljanske burze

datum	SBITOP	CICG	GRVG	IEKG	KRKG	LKPG	PETG	POSR	TLSG	UKIG	ZVTG
1.1.2016											
8.1.2016	-0,0220	0,0000	-0,0220	0,0370	-0,0455	-0,0332	-0,0269	-0,0250	0,0128	-0,0031	0,0211
15.1.2016	-0,0162	0,0000	-0,0225	0,2122	-0,0262	-0,0366	0,0040	-0,0346	-0,0103	0,0121	-0,0126
22.1.2016	0,0085	-0,0132	0,0173	-0,2013	0,0018	0,0471	0,0198	-0,0161	-0,0095	-0,0408	0,0063
29.1.2016	0,0190	-0,0148	0,0051	0,1073	0,0195	0,0218	0,0194	0,0707	0,0000	0,0183	0,0063
5.2.2016	-0,0126	-0,0068	-0,0083	-0,1164	-0,0138	-0,0260	-0,0153	-0,0303	0,0137	0,0000	-0,0105
12.2.2016	-0,0186	-0,0195	-0,0372	0,0835	-0,0107	-0,0775	0,0118	-0,0576	-0,0177	0,0090	-0,0364
19.2.2016	0,0104	-0,0137	-0,0037	-0,1037	0,0008	0,0134	0,0111	0,0118	0,0041	-0,0018	0,0385
26.2.2016	0,0159	0,0028	0,0267	-0,0552	0,0156	0,0071	0,0200	0,0458	0,0134	-0,0481	-0,0061
4.3.2016	0,0134	0,0386	-0,0025	0,0717	-0,0082	0,0273	0,0174	-0,0008	0,0270	0,0853	0,0473
11.3.2016	0,0246	0,0654	-0,0158	0,0549	0,0057	0,0566	0,0102	0,0925	0,0261	-0,0087	0,0476
18.3.2016	0,0035	0,0126	-0,0232	-0,1286	-0,0074	0,0270	0,0080	0,0224	0,0193	-0,0357	-0,0128
25.3.2016	0,0074	0,0308	0,0415	0,0078	0,0033	-0,0119	-0,0018	0,0205	-0,0001	-0,0005	0,0333
1.4.2016	0,0036	0,0000	-0,0059	0,0493	-0,0031	-0,0108	0,0110	0,0139	-0,0062	-0,0087	0,0166
8.4.2016	0,0007	-0,0061	0,0105	0,0183	0,0015	-0,0087	0,0123	-0,0280	-0,0194	0,0078	0,0131
15.4.2016	-0,0098	-0,0247	0,0614	-0,0333	-0,0025	0,0041	-0,0415	0,0314	-0,0078	-0,0357	-0,0222
22.4.2016	0,0035	-0,0251	0,0211	-0,0019	-0,0005	-0,0107	0,0152	-0,0028	-0,0185	0,0379	0,0134
29.4.2016	-0,0090	0,0226	0,0800	0,1205	-0,0033	0,0109	-0,0504	0,0195	0,0000	0,0348	-0,0115
6.5.2016	0,0034	0,0038	0,0000	-0,1395	-0,0020	-0,0175	0,0114	-0,0133	0,0263	0,0429	0,0043
13.5.2016	0,0007	0,0416	0,0190	0,1577	0,0000	0,0175	-0,0080	0,0000	-0,0003	0,0884	0,0035
20.5.2016	-0,0099	-0,0181	0,1159	-0,1017	-0,0243	0,0000	0,0000	-0,0069	-0,0531	0,0741	-0,0198
27.5.2016	-0,0019	-0,0123	0,0298	0,3527	-0,0008	0,0000	0,0057	0,0065	-0,0278	0,0000	-0,0179
3.6.2016	-0,0170	0,0110	0,0078	-0,0443	0,0084	0,0000	-0,0091	-0,0204	-0,0071	0,0351	-0,1174
10.6.2016	-0,0018	-0,0474	0,0583	-0,0690	-0,0100	-0,0127	0,0038	0,0070	-0,0014	-0,0531	-0,0254
17.6.2016	-0,0181	0,0050	-0,0200	0,2513	-0,0239	-0,0245	-0,0270	0,0000	-0,0057	-0,0561	-0,0044
24.6.2016	0,0002	0,0082	-0,0677	0,0488	-0,0003	0,0152	0,0195	-0,0105	0,0016	0,0377	-0,0067
1.7.2016	0,0096	-0,0140	0,0408	0,0000	0,0087	0,0132	0,0074	-0,0007	0,0055	0,1382	0,0094
8.7.2016	0,0205	0,0121	0,0392	-0,0053	0,0086	0,0079	0,0115	0,0181	0,0483	-0,0469	0,0433
15.7.2016	-0,0013	0,0732	0,0228	-0,1113	-0,0437	-0,0323	0,0507	0,0069	-0,0135	0,0007	-0,0023

22.7.2016	0,0035	0,0333	-0,0038	-0,0132	0,0245	0,0067	-0,0054	-0,0208	-0,0138	-0,0136	0,0085
29.7.2016	0,0229	-0,0216	0,1504	-0,0368	0,0361	0,0219	-0,0018	0,0042	0,0000	0,0068	0,0063
5.8.2016	-0,0124	0,0230	-0,0741	0,1408	-0,0169	-0,0127	-0,0181	0,0097	0,0138	0,0202	0,0084
12.8.2016	0,0065	-0,0230	0,0208	0,0204	-0,0033	0,0038	0,0095	0,0171	-0,0069	0,0520	0,0206
19.8.2016	0,0139	0,0342	0,0403	0,0639	0,0269	-0,0062	0,0158	0,0121	0,0205	0,0367	-0,0290
26.8.2016	0,0123	0,0112	0,0260	0,0842	-0,0059	0,0191	0,0368	0,0047	-0,0068	0,0067	0,0119
2.9.2016	-0,0010	-0,0396	-0,0194	0,0091	0,0074	0,0007	0,0110	-0,0478	-0,0096	0,0870	0,0027
9.9.2016	0,0051	-0,0187	0,0815	0,0870	-0,0017	-0,0109	0,0042	-0,0070	-0,0028	0,0000	-0,0004
16.9.2016	0,0038	0,0256	0,0000	0,1178	0,0018	-0,0053	0,0319	-0,0124	-0,0083	0,0000	-0,0269
23.9.2016	0,0060	0,0741	0,0179	-0,0722	-0,0048	0,0270	0,0269	0,0025	-0,0140	0,0000	-0,0176
30.9.2016	-0,0038	0,0789	-0,0673	-0,0960	0,0360	-0,0108	-0,0213	-0,0050	0,0031	0,0000	-0,0259
7.10.2016	-0,0059	0,0000	-0,0044	0,0070	-0,0385	0,0000	0,0237	-0,0050	0,0027	0,0279	-0,0045
14.10.2016	-0,0181	-0,0568	0,0294	-0,0573	-0,0134	0,0004	-0,0367	-0,0531	-0,0036	-0,0169	-0,0167
21.10.2016	0,0213	0,0518	0,1164	-0,0424	-0,0020	0,0039	0,0381	-0,0137	0,0000	0,0377	0,0255
28.10.2016	0,0093	0,0196	-0,0357	0,1005	-0,0026	0,0022	0,0181	0,0473	0,0174	-0,0764	0,0223
4.11.2016	-0,0086	-0,0098	0,0010	0,0000	-0,0086	-0,0022	-0,0086	-0,0260	-0,0125	-0,0006	-0,0048
11.11.2016	-0,0083	0,0107	-0,0195	-0,0910	0,0000	-0,0131	-0,0223	0,0000	0,0035	0,0000	0,0009
18.11.2016	-0,0314	0,2116	-0,3623	-0,0086	-0,0349	0,0087	0,0223	0,0052	-0,0176	0,0474	-0,0228
25.11.2016	-0,0074	0,0719	0,0083	-0,0135	-0,0365	0,0000	0,0031	0,0000	0,0071	-0,0082	0,0066
2.12.2016	-0,0188	-0,0118	-0,0251	0,1131	-0,0548	-0,0083	-0,0063	-0,0068	-0,0140	0,0430	0,0013
9.12.2016	0,0178	0,0829	-0,0119	0,0061	0,0418	0,0083	-0,0027	-0,0136	0,0337	-0,0267	0,0149
16.12.2016	0,0070	0,0965	0,0034	0,0323	-0,0083	0,0591	0,0062	0,0038	-0,0057	-0,0556	0,0080
23.12.2016	-0,0074	-0,0118	-0,0060	-0,0211	-0,0358	0,0193	0,0028	0,0151	-0,0028	0,1235	-0,0024
30.12.2016	0,0174	0,0124	0,0305	0,0085	0,0366	0,0050	0,0218	-0,0098	-0,0098	-0,0153	0,0022
6.1.2017	0,0157	0,0470	0,0095	0,0953	-0,0009	-2,9581	-0,0146	0,0254	0,0784	-0,0046	0,0422
13.1.2017	0,0094	0,0129	0,0714	-0,0140	-0,0103	-0,0140	0,0054	0,0472	0,0142	0,0097	0,0033
20.1.2017	0,0029	-0,0117	-0,0218	0,0752	-0,0056	0,0752	0,0153	0,0410	0,0000	0,0152	0,0016
27.1.2017	0,0087	0,0175	-0,0095	0,0043	0,0073	0,0043	0,0061	0,0127	0,0377	-0,0050	0,0080
3.2.2017	-0,0004	0,0000	0,0000	0,0451	-0,0077	0,0451	-0,0061	0,0000	0,0025	0,0075	0,0156
10.2.2017	0,0152	0,0589	0,0002	0,0557	-0,0192	0,0557	0,0150	0,0831	0,0098	-0,0075	0,0585
17.2.2017	0,0094	0,0319	0,0354	0,2040	0,0018	0,2040	-0,0059	-0,0068	0,0470	0,0000	-0,0076
24.2.2017	0,0155	0,0113	0,0110	-0,0535	0,0078	-0,0535	0,0326	0,0370	0,0075	-0,0122	0,0121

3.3.2017	0,0246	0,0176	0,0036	0,0374	0,0276	0,0374	0,0488	0,0089	0,0046	0,0215	-0,0080
10.3.2017	-0,0006	-0,0411	0,0623	-0,0851	-0,0072	-0,0851	-0,0056	-0,0330	-0,0140	-0,0070	0,0185
17.3.2017	0,0105	0,0146	0,0217	-0,1246	0,0083	-0,1246	-0,0112	-0,0061	0,0163	-0,0129	0,0294
24.3.2017	-0,0126	-0,0483	-0,0022	0,0139	0,0000	0,0139	-0,0130	-0,0003	-0,0139	-0,0306	-0,0183
31.3.2017	-0,0217	0,0200	-0,0266	0,1095	-0,0162	0,1095	-0,0335	-0,0058	0,0091	0,0206	-0,0414
7.4.2017	0,0061	-0,0247	-0,0661	-0,0526	0,0181	-0,0526	0,0117	-0,0077	-0,0091	0,0105	0,0228
14.4.2017	-0,0015	-0,0339	0,0298	0,0834	-0,0043	0,0834	0,0146	0,0016	-0,0235	-0,0258	-0,0152
21.4.2017	-0,0062	0,0052	-0,0225	0,0017	-0,0147	0,0017	0,0029	-0,0283	-0,0036	0,0104	0,0121
28.4.2017	0,0114	0,0392	0,0075	0,0265	0,0038	0,0265	0,0143	0,0095	0,0269	-0,0157	0,0075
5.5.2017	-0,0067	-0,0166	-0,0148	-0,0501	-0,0135	-0,0501	0,0113	-0,0159	-0,0209	-0,0159	0,0102
12.5.2017	0,0071	-0,0226	0,0148	-0,0059	0,0362	-0,0059	-0,0071	0,0000	-0,0006	-0,0029	-0,0043
19.5.2017	0,0026	0,0875	-0,0075	0,0278	-0,0094	0,0278	0,0076	0,0032	-0,0174	-0,0264	0,0054
26.5.2017	0,0056	0,0202	0,0225	0,0875	-0,0021	0,0875	0,0052	0,0234	0,0036	0,0003	0,0028
2.6.2017	0,0024	-0,0255	-0,0455	0,0156	0,0023	0,0156	0,0082	0,0019	-0,0024	0,0183	0,0092
9.6.2017	0,0015	-0,0313	-0,0047	0,0000	0,0036	0,0000	0,0000	0,0155	0,0024	0,0016	0,0009
16.6.2017	-0,0101	-0,0063	-0,0110	-0,0104	0,0062	-0,0104	0,0033	-0,0694	0,0185	-0,0346	-0,0944
23.6.2017	0,0101	-0,0728	-0,0079	0,0155	0,0180	0,0155	0,0321	0,0219	-0,0161	0,0330	0,0020
30.6.2017	0,0053	-0,0157	0,0000	-0,0202	0,0091	-0,0202	0,0053	-0,0252	0,0214	-0,0246	0,0016

Prilog 5: Tjedne cijene zatvaranja odabranih dionica sa Beogradske burze

datum	BELEXline	AERO	ALFA	ENHL	FITO	IMPL	KMBN	MTLC	NIIS	SJPT	TGAS
1.1.2016	1380,42	1153,00	32138,00	1037,00	2375,00	1094,00	1575,00	2450,00	600,00	887,00	8700,00
8.1.2016	1358,72	1122,00	33930,00	999,00	2399,00	1124,00	1624,00	2400,00	596,00	900,00	8585,00
15.1.2016	1314,97	995,00	32300,00	930,00	2200,00	1100,00	1587,00	2350,00	552,00	900,00	8350,00
22.1.2016	1272,79	907,00	31860,00	911,00	2203,00	1051,00	1580,00	2389,00	506,00	845,00	8139,00
29.1.2016	1313,73	948,00	31000,00	998,00	2216,00	1000,00	1550,00	2490,00	561,00	850,00	7900,00
5.2.2016	1296,44	946,00	31741,00	942,00	2216,00	1033,00	1570,00	2500,00	561,00	903,00	7800,00
12.2.2016	1273,91	910,00	31000,00	931,00	2250,00	1000,00	1512,00	2570,00	548,00	850,00	7834,00
19.2.2016	1266,41	903,00	31000,00	901,00	2299,00	955,00	1465,00	2500,00	548,00	847,00	7872,00
26.2.2016	1292,56	942,00	31101,00	947,00	2209,00	914,00	1450,00	2621,00	539,00	840,00	8200,00
4.3.2016	1291,77	925,00	33000,00	931,00	2232,00	980,00	1499,00	2529,00	563,00	850,00	8250,00
11.3.2016	1299,33	940,00	33417,00	971,00	2296,00	965,00	1462,00	2511,00	580,00	871,00	8050,00
18.3.2016	1308,71	960,00	32600,00	971,00	2300,00	996,00	1450,00	2550,00	586,00	853,00	8000,00
25.3.2016	1324,31	979,00	33005,00	997,00	2450,00	970,00	1405,00	2522,00	591,00	880,00	8750,00
1.4.2016	1339,13	960,00	32700,00	999,00	2420,00	1551,00	1388,00	2571,00	580,00	889,00	8698,00
8.4.2016	1347,89	925,00	34901,00	1050,00	2563,00	1623,00	1401,00	2542,00	603,00	890,00	8568,00
15.4.2016	1344,63	884,00	34000,00	1028,00	2580,00	1765,00	1450,00	2551,00	603,00	889,00	8400,00
22.4.2016	1326,31	879,00	33001,00	1014,00	2500,00	1910,00	1410,00	2600,00	605,00	836,00	8265,00
29.4.2016	1344,85	891,00	33001,00	1070,00	2505,00	1550,00	1430,00	2747,00	610,00	800,00	9998,00
6.5.2016	1346,97	890,00	33001,00	1048,00	2500,00	1550,00	1427,00	2750,00	608,00	886,00	10000,00
13.5.2016	1347,28	897,00	33001,00	1094,00	2415,00	1551,00	1413,00	2758,00	621,00	825,00	9592,00
20.5.2016	1348,87	885,00	33001,00	1080,00	2450,00	1550,00	1450,00	2702,00	635,00	887,00	8081,00
27.5.2016	1309,24	895,00	34000,00	1100,00	2541,00	1550,00	1450,00	1351,00	647,00	818,00	8001,00
3.6.2016	1358,25	900,00	34999,00	1200,00	2600,00	1570,00	1502,00	1500,00	642,00	821,00	8098,00
10.6.2016	1351,54	910,00	34999,00	1201,00	2641,00	1601,00	1507,00	1445,00	652,00	781,00	8199,00
17.6.2016	1352,38	916,00	34999,00	1200,00	2797,00	1624,00	1487,00	1380,00	625,00	800,00	8205,00
24.6.2016	1331,81	900,00	32000,00	1200,00	2650,00	1697,00	1458,00	1360,00	614,00	760,00	8204,00
1.7.2016	1323,42	896,00	31000,00	1200,00	2551,00	1631,00	1425,00	1379,00	620,00	750,00	8237,00
8.7.2016	1309,08	910,00	31000,00	1205,00	2600,00	1631,00	1402,00	1367,00	620,00	701,00	8150,00
15.7.2016	1344,69	943,00	32000,00	1201,00	2798,00	1715,00	1450,00	1470,00	625,00	660,00	8498,00

22.7.2016	1336,45	974,00	31000,00	1200,00	2617,00	1716,00	1402,00	1400,00	615,00	679,00	8943,00
29.7.2016	1385,42	1000,00	31000,00	1233,00	2871,00	1751,00	1595,00	1400,00	615,00	699,00	9399,00
5.8.2016	1392,62	983,00	31000,00	1250,00	2987,00	1898,00	1553,00	1420,00	606,00	731,00	10036,00
12.8.2016	1390,00	1047,00	31005,00	1253,00	2851,00	2000,00	1520,00	1420,00	581,00	691,00	11305,00
19.8.2016	1369,66	1018,00	31202,00	1233,00	2850,00	2008,00	1400,00	1400,00	584,00	660,00	10501,00
26.8.2016	1370,93	1078,00	31000,00	1250,00	2675,00	2047,00	1449,00	1430,00	572,00	657,00	10000,00
2.9.2016	1393,17	1076,00	31000,00	1247,00	2819,00	2201,00	1498,00	1448,00	575,00	670,00	10494,00
9.9.2016	1415,45	1106,00	31943,00	1250,00	2819,00	2200,00	1490,00	1401,00	609,00	649,00	10600,00
16.9.2016	1414,31	1068,00	32000,00	1234,00	2763,00	2200,00	1490,00	1400,00	597,00	651,00	11200,00
23.9.2016	1429,61	1075,00	32000,00	1250,00	2788,00	2050,00	1550,00	1430,00	598,00	654,00	11223,00
30.9.2016	1439,04	1059,00	32000,00	1250,00	2798,00	2073,00	1548,00	1400,00	590,00	659,00	11380,00
7.10.2016	1452,08	1056,00	32500,00	1291,00	2754,00	2171,00	1552,00	1405,00	600,00	645,00	11024,00
14.10.2016	1447,00	1018,00	32500,00	1295,00	2717,00	2170,00	1600,00	1429,00	601,00	645,00	11170,00
21.10.2016	1474,35	1175,00	33000,00	1346,00	2779,00	2200,00	1650,00	1405,00	630,00	641,00	11300,00
28.10.2016	1497,35	1133,00	32804,00	1345,00	2875,00	2338,00	1678,00	1441,00	651,00	638,00	11500,00
4.11.2016	1495,83	1099,00	34350,00	1360,00	2780,00	2460,00	1629,00	1490,00	633,00	620,00	11600,00
11.11.2016	1495,46	1090,00	34150,00	1384,00	2780,00	2510,00	1600,00	1432,00	633,00	621,00	11600,00
18.11.2016	1503,82	1107,00	33000,00	1394,00	2897,00	2492,00	1625,00	1477,00	637,00	603,00	12002,00
25.11.2016	1524,98	1094,00	34000,00	1400,00	2833,00	2508,00	1697,00	1530,00	678,00	607,00	12500,00
2.12.2016	1552,52	1107,00	34000,00	1420,00	2799,00	2600,00	1750,00	1600,00	711,00	630,00	13000,00
9.12.2016	1586,29	1198,00	34000,00	1410,00	2761,00	2619,00	1711,00	1650,00	730,00	636,00	13945,00
16.12.2016	1576,23	1174,00	34000,00	1434,00	2800,00	2700,00	1703,00	1620,00	744,00	640,00	13690,00
23.12.2016	1561,88	1156,00	34500,00	1401,00	2719,00	2611,00	1682,00	1679,00	737,00	640,00	13210,00
30.12.2016	1569,43	1156,00	35000,00	1431,00	2720,00	2654,00	1738,00	1686,00	740,00	618,00	13006,00
6.1.2017	1566,62	1141,00	35000,00	1400,00	2720,00	2661,00	1700,00	1740,00	748,00	640,00	13006,00
13.1.2017	1560,80	1127,00	33100,00	1399,00	2700,00	2681,00	1700,00	1807,00	742,00	651,00	13086,00
20.1.2017	1540,08	1100,00	33020,00	1301,00	2700,00	2691,00	1701,00	1800,00	745,00	640,00	13007,00
27.1.2017	1533,98	1100,00	33096,00	1262,00	2700,00	2732,00	1724,00	1707,00	741,00	640,00	12999,00
3.2.2017	1536,27	1121,00	34994,00	1209,00	2651,00	2800,00	1719,00	1760,00	742,00	659,00	12980,00
10.2.2017	1537,55	1130,00	33789,00	1214,00	2710,00	3033,00	1790,00	1700,00	744,00	657,00	13000,00
17.2.2017	1547,29	1162,00	35000,00	1261,00	2696,00	3000,00	1772,00	1700,00	749,00	649,00	13160,00
24.2.2017	1563,89	1175,00	35000,00	1300,00	2710,00	3013,00	1749,00	1761,00	751,00	650,00	13371,00

3.3.2017	1578,33	1201,00	33006,00	1340,00	2700,00	3011,00	1712,00	1760,00	774,00	648,00	13602,00
10.3.2017	1614,86	1261,00	35500,00	1460,00	2710,00	3037,00	1748,00	1799,00	756,00	636,00	13573,00
17.3.2017	1617,50	1377,00	35001,00	1450,00	2707,00	3113,00	1761,00	1770,00	740,00	593,00	13410,00
24.3.2017	1623,70	1330,00	35001,00	1456,00	2720,00	3398,00	1776,00	1799,00	747,00	600,00	13900,00
31.3.2017	1603,70	1300,00	35003,00	1489,00	2740,00	3500,00	1655,00	1800,00	747,00	545,00	12650,00
7.4.2017	1594,01	1283,00	35000,00	1501,00	2703,00	3441,00	1653,00	1800,00	746,00	540,00	12100,00
14.4.2017	1585,43	1306,00	35500,00	1501,00	2750,00	3401,00	1700,00	1801,00	756,00	496,00	11100,00
21.4.2017	1584,99	1284,00	35000,00	1501,00	2700,00	3367,00	1800,00	1681,00	756,00	520,00	11263,00
28.4.2017	1577,39	1316,00	34001,00	1350,00	2699,00	3359,00	1780,00	1693,00	745,00	512,00	11250,00
5.5.2017	1571,95	1300,00	34001,00	1361,00	2700,00	3300,00	1750,00	1692,00	729,00	530,00	11250,00
12.5.2017	1576,97	1307,00	35019,00	1400,00	2700,00	3280,00	1786,00	1720,00	747,00	513,00	11112,00
19.5.2017	1590,60	1306,00	35500,00	1496,00	2700,00	3350,00	1869,00	1736,00	745,00	500,00	11000,00
26.5.2017	1556,26	1257,00	35001,00	1410,00	2600,00	3356,00	1805,00	1730,00	736,00	491,00	10901,00
2.6.2017	1563,46	1276,00	35001,00	1402,00	2680,00	3396,00	1810,00	1740,00	727,00	500,00	10500,00
9.6.2017	1550,60	1293,00	34000,00	1453,00	2606,00	3300,00	1801,00	1740,00	710,00	464,00	11200,00
16.6.2017	1539,38	1281,00	34000,00	1418,00	2650,00	3491,00	1794,00	1750,00	690,00	444,00	10983,00
23.6.2017	1533,65	1288,00	34000,00	1441,00	2620,00	3455,00	1771,00	1752,00	665,00	429,00	11200,00
30.6.2017	1542,38	1286,00	34500,00	1450,00	2630,00	3373,00	1800,00	1760,00	676,00	427,00	11301,00

Prilog 6: Tjedni prinosi odabranih dionica sa Beogradske burze

datum	BELEXline	AERO	ALFA	ENHL	FITO	IMPL	KMBN	MTLC	NIIS	SJPT	TGAS
1.1.2016											
8.1.2016	-0,01584	-0,02725	0,05426	-0,03733	0,01005	0,02705	0,03064	-0,02062	-0,00669	0,01455	-0,01331
15.1.2016	-0,03273	-0,12013	-0,04923	-0,07157	-0,08659	-0,02158	-0,02305	-0,02105	-0,07669	0,00000	-0,02775
22.1.2016	-0,03260	-0,09260	-0,01372	-0,02064	0,00136	-0,04557	-0,00442	0,01646	-0,08701	-0,06306	-0,02559
29.1.2016	0,03166	0,04421	-0,02736	0,09121	0,00588	-0,04974	-0,01917	0,04141	0,10318	0,00590	-0,02980
5.2.2016	-0,01325	-0,00211	0,02362	-0,05775	0,00000	0,03247	0,01282	0,00401	0,00000	0,06049	-0,01274
12.2.2016	-0,01753	-0,03880	-0,02362	-0,01175	0,01523	-0,03247	-0,03764	0,02762	-0,02345	-0,06049	0,00435
19.2.2016	-0,00590	-0,00772	0,00000	-0,03275	0,02154	-0,04604	-0,03158	-0,02762	0,00000	-0,00354	0,00484
26.2.2016	0,02044	0,04228	0,00325	0,04979	-0,03993	-0,04388	-0,01029	0,04727	-0,01656	-0,00830	0,04082
4.3.2016	-0,00061	-0,01821	0,05927	-0,01704	0,01036	0,06972	0,03323	-0,03573	0,04356	0,01183	0,00608
11.3.2016	0,00584	0,01609	0,01256	0,04207	0,02827	-0,01542	-0,02499	-0,00714	0,02975	0,02441	-0,02454
18.3.2016	0,00719	0,02105	-0,02475	0,00000	0,00174	0,03162	-0,00824	0,01541	0,01029	-0,02088	-0,00623
25.3.2016	0,01185	0,01960	0,01235	0,02642	0,06318	-0,02645	-0,03153	-0,01104	0,00850	0,03116	0,08961
1.4.2016	0,01113	-0,01960	-0,00928	0,00200	-0,01232	0,46936	-0,01217	0,01924	-0,01879	0,01018	-0,00596
8.4.2016	0,00652	-0,03714	0,06514	0,04979	0,05741	0,04538	0,00932	-0,01134	0,03889	0,00112	-0,01506
15.4.2016	-0,00242	-0,04534	-0,02615	-0,02117	0,00661	0,08387	0,03438	0,00353	0,00000	-0,00112	-0,01980
22.4.2016	-0,01372	-0,00567	-0,02982	-0,01371	-0,03150	0,07895	-0,02797	0,01903	0,00331	-0,06147	-0,01620
29.4.2016	0,01388	0,01356	0,00000	0,05376	0,00200	-0,20885	0,01408	0,05500	0,00823	-0,04402	0,19036
6.5.2016	0,00158	-0,00112	0,00000	-0,02078	-0,00200	0,00000	-0,00210	0,00109	-0,00328	0,10211	0,00020
13.5.2016	0,00023	0,00783	0,00000	0,04296	-0,03459	0,00064	-0,00986	0,00290	0,02116	-0,07133	-0,04166
20.5.2016	0,00118	-0,01347	0,00000	-0,01288	0,01439	-0,00064	0,02585	-0,02051	0,02229	0,07246	-0,17141
27.5.2016	-0,02982	0,01124	0,02982	0,01835	0,03647	0,00000	0,00000	-0,69315	0,01872	-0,08098	-0,00995
3.6.2016	0,03675	0,00557	0,02896	0,08701	0,02295	0,01282	0,03523	0,10462	-0,00776	0,00366	0,01205
10.6.2016	-0,00495	0,01105	0,00000	0,00083	0,01565	0,01955	0,00332	-0,03736	0,01546	-0,04995	0,01240
17.6.2016	0,00062	0,00657	0,00000	-0,00083	0,05739	0,01426	-0,01336	-0,04603	-0,04229	0,02404	0,00073
24.6.2016	-0,01533	-0,01762	-0,08958	0,00000	-0,05399	0,04397	-0,01970	-0,01460	-0,01776	-0,05129	-0,00012
1.7.2016	-0,00632	-0,00445	-0,03175	0,00000	-0,03807	-0,03967	-0,02289	0,01387	0,00972	-0,01325	0,00401
8.7.2016	-0,01089	0,01550	0,00000	0,00416	0,01903	0,00000	-0,01627	-0,00874	0,00000	-0,06757	-0,01062
15.7.2016	0,02684	0,03562	0,03175	-0,00333	0,07339	0,05022	0,03366	0,07264	0,00803	-0,06027	0,04181

22.7.2016	-0,00615	0,03235	-0,03175	-0,00083	-0,06688	0,00058	-0,03366	-0,04879	-0,01613	0,02838	0,05104
29.7.2016	0,03599	0,02634	0,00000	0,02713	0,09263	0,02019	0,12897	0,00000	0,00000	0,02903	0,04973
5.8.2016	0,00518	-0,01715	0,00000	0,01369	0,03961	0,08061	-0,02669	0,01418	-0,01474	0,04476	0,06558
12.8.2016	-0,00188	0,06308	0,00016	0,00240	-0,04660	0,05235	-0,02148	0,00000	-0,04213	-0,05627	0,11907
19.8.2016	-0,01474	-0,02809	0,00633	-0,01609	-0,00035	0,00399	-0,08224	-0,01418	0,00515	-0,04590	-0,07377
26.8.2016	0,00093	0,05727	-0,00649	0,01369	-0,06337	0,01924	0,03440	0,02120	-0,02076	-0,00456	-0,04889
2.9.2016	0,01609	-0,00186	0,00000	-0,00240	0,05243	0,07254	0,03326	0,01251	0,00523	0,01959	0,04822
9.9.2016	0,01587	0,02750	0,02997	0,00240	0,00000	-0,00045	-0,00535	-0,03300	0,05745	-0,03184	0,01005
16.9.2016	-0,00081	-0,03496	0,00178	-0,01288	-0,02007	0,00000	0,00000	-0,00071	-0,01990	0,00308	0,05506
23.9.2016	0,01076	0,00653	0,00000	0,01288	0,00901	-0,07062	0,03948	0,02120	0,00167	0,00460	0,00205
30.9.2016	0,00657	-0,01500	0,00000	0,00000	0,00358	0,01116	-0,00129	-0,02120	-0,01347	0,00762	0,01389
7.10.2016	0,00902	-0,00284	0,01550	0,03227	-0,01585	0,04619	0,00258	0,00357	0,01681	-0,02147	-0,03178
14.10.2016	-0,00350	-0,03665	0,00000	0,00309	-0,01353	-0,00046	0,03046	0,01694	0,00167	0,00000	0,01316
21.10.2016	0,01872	0,14343	0,01527	0,03863	0,02256	0,01373	0,03077	-0,01694	0,04712	-0,00622	0,01157
28.10.2016	0,01548	-0,03640	-0,00596	-0,00074	0,03396	0,06084	0,01683	0,02530	0,03279	-0,00469	0,01754
4.11.2016	-0,00102	-0,03047	0,04605	0,01109	-0,03360	0,05087	-0,02964	0,03344	-0,02804	-0,02862	0,00866
11.11.2016	-0,00025	-0,00822	-0,00584	0,01749	0,00000	0,02012	-0,01796	-0,03970	0,00000	0,00161	0,00000
18.11.2016	0,00557	0,01548	-0,03426	0,00720	0,04122	-0,00720	0,01550	0,03094	0,00630	-0,02941	0,03407
25.11.2016	0,01397	-0,01181	0,02985	0,00429	-0,02234	0,00640	0,04335	0,03525	0,06238	0,00661	0,04066
2.12.2016	0,01790	0,01181	0,00000	0,01418	-0,01207	0,03603	0,03075	0,04474	0,04753	0,03719	0,03922
9.12.2016	0,02152	0,07900	0,00000	-0,00707	-0,01367	0,00728	-0,02254	0,03077	0,02637	0,00948	0,07017
16.12.2016	-0,00636	-0,02024	0,00000	0,01688	0,01403	0,03046	-0,00469	-0,01835	0,01900	0,00627	-0,01846
23.12.2016	-0,00915	-0,01545	0,01460	-0,02328	-0,02936	-0,03352	-0,01241	0,03577	-0,00945	0,00000	-0,03569
30.12.2016	0,00482	0,00000	0,01439	0,02119	0,00037	0,01633	0,03275	0,00416	0,00406	-0,03498	-0,01556
6.1.2017	-0,00179	-0,01306	0,00000	-0,02190	0,00000	0,00263	-0,02211	0,03153	0,01075	0,03498	0,00000
13.1.2017	-0,00372	-0,01235	-0,05581	-0,00071	-0,00738	0,00749	0,00000	0,03778	-0,00805	0,01704	0,00613
20.1.2017	-0,01336	-0,02425	-0,00242	-0,07262	0,00000	0,00372	0,00059	-0,00388	0,00403	-0,01704	-0,00606
27.1.2017	-0,00397	0,00000	0,00230	-0,03044	0,00000	0,01512	0,01343	-0,05305	-0,00538	0,00000	-0,00062
3.2.2017	0,00149	0,01891	0,05576	-0,04290	-0,01831	0,02459	-0,00290	0,03058	0,00135	0,02926	-0,00146
10.2.2017	0,00083	0,00800	-0,03504	0,00413	0,02201	0,07993	0,04047	-0,03469	0,00269	-0,00304	0,00154
17.2.2017	0,00631	0,02793	0,03521	0,03798	-0,00518	-0,01094	-0,01011	0,00000	0,00670	-0,01225	0,01223
24.2.2017	0,01067	0,01113	0,00000	0,03046	0,00518	0,00432	-0,01306	0,03525	0,00267	0,00154	0,01591

3.3.2017	0,00919	0,02189	-0,05866	0,03031	-0,00370	-0,00066	-0,02138	-0,00057	0,03017	-0,00308	0,01713
10.3.2017	0,02288	0,04875	0,07284	0,08577	0,00370	0,00860	0,02081	0,02192	-0,02353	-0,01869	-0,00213
17.3.2017	0,00163	0,08800	-0,01416	-0,00687	-0,00111	0,02472	0,00741	-0,01625	-0,02139	-0,07000	-0,01208
24.3.2017	0,00383	-0,03473	0,00000	0,00413	0,00479	0,08760	0,00848	0,01625	0,00941	0,01174	0,03589
31.3.2017	-0,01239	-0,02281	0,00006	0,02241	0,00733	0,02958	-0,07056	0,00056	0,00000	-0,09614	-0,09423
7.4.2017	-0,00606	-0,01316	-0,00009	0,00803	-0,01360	-0,01700	-0,00121	0,00000	-0,00134	-0,00922	-0,04445
14.4.2017	-0,00540	0,01777	0,01418	0,00000	0,01724	-0,01169	0,02804	0,00056	0,01332	-0,08499	-0,08626
21.4.2017	-0,00028	-0,01699	-0,01418	0,00000	-0,01835	-0,01005	0,05716	-0,06895	0,00000	0,04725	0,01458
28.4.2017	-0,00481	0,02462	-0,02896	-0,10603	-0,00037	-0,00238	-0,01117	0,00711	-0,01466	-0,01550	-0,00115
5.5.2017	-0,00345	-0,01223	0,00000	0,00812	0,00037	-0,01772	-0,01700	-0,00059	-0,02171	0,03455	0,00000
12.5.2017	0,00319	0,00537	0,02950	0,02825	0,00000	-0,00608	0,02036	0,01641	0,02439	-0,03260	-0,01234
19.5.2017	0,00861	-0,00077	0,01364	0,06632	0,00000	0,02112	0,04543	0,00926	-0,00268	-0,02567	-0,01013
26.5.2017	-0,02183	-0,03824	-0,01416	-0,05921	-0,03774	0,00179	-0,03484	-0,00346	-0,01215	-0,01816	-0,00904
2.6.2017	0,00462	0,01500	0,00000	-0,00569	0,03031	0,01185	0,00277	0,00576	-0,01230	0,01816	-0,03748
9.6.2017	-0,00826	0,01323	-0,02902	0,03573	-0,02800	-0,02868	-0,00498	0,00000	-0,02366	-0,07472	0,06454
16.6.2017	-0,00726	-0,00932	0,00000	-0,02438	0,01674	0,05627	-0,00389	0,00573	-0,02857	-0,04406	-0,01957
23.6.2017	-0,00373	0,00545	0,00000	0,01609	-0,01139	-0,01037	-0,01290	0,00114	-0,03690	-0,03437	0,01957
30.6.2017	0,00568	-0,00155	0,01460	0,00623	0,00381	-0,02402	0,01624	0,00456	0,01641	-0,00467	0,00898

POPIS SLIKA

Slika 1. Funkcija korisnosti investitora koji izbjegava rizik, investitora koji je indiferentan u odnosu na rizik, i investitora koji je sklon riziku

Slika 2. Skup mogućih portfelja

Slika 3. a) Skup minimalne varijance **b)** Efikasna granica

Slika 4. Ukupni, sustavni i nesustavni rizik

Slika 5. Primjer desnostrane i ljevostrane distribucije

Slika 6. Efikasna granica različitih kombinacija financijske aktive i investicijskih strategija

Slika 7. Efikasna granica na hrvatskom tržištu kapitala

Slika 8. Efikasna granica na slovenskom tržištu kapitala

Slika 9. Efikasna granica na srbijanskom tržištu kapitala

Slika 10. Efikasne granice na hrvatskom, slovenskom i srbijanskom tržištu kapitala izračunate primjenom MV modela

Slika 11. Efikasna granica na hrvatskom tržištu kapitala s donjom polu-standardnom devijacijom kao mjerom rizika

Slika 12. Efikasna granica na slovenskom tržištu kapitala s donjom polu-standardnom devijacijom kao mjerom rizika

Slika 13. Efikasna granica na srbijanskom tržištu kapitala s donjom polu-standardnom devijacijom kao mjerom rizika

Slika 14. Efikasne granice na hrvatskom, slovenskom i srbijanskom tržištu kapitala izračunate primjenom donje polu-varijance kao mjere rizika

POPIS TABLICA

Tablica 1. Odabrane dionice sa Zagrebačke burze

Tablica 2. Statistički podaci o prinosima na hrvatskom tržištu kapitala

Tablica 3. Kolmogorov-Smirnov test za hrvatsko tržište kapitala

Tablica 4. Odabrane dionice s Ljubljanske burze

Tablica 5. Statistički podaci o prinosima na slovenskom tržištu kapitala

Tablica 6. Kolmogorov-Smirnov test za slovensko tržište kapitala

Tablica 7. Odabrane dionice s Beogradske burze

Tablica 8. Statistički podaci o prinosima na srbijanskom tržištu kapitala

Tablica 9. Kolmogorov-Smirnov test za srbijansko tržište kapitala

Tablica 10. Matrica varijanci i kovarijanci dionica sa Zagrebačke burze

Tablica 11. Efikasni portfelji na hrvatskom tržištu kapitala

Tablica 12. Matrica varijanci i kovarijanci dionica s Ljubljanske burze

Tablica 13. Efikasni portfelji na slovenskom tržištu kapitala

Tablica 14. Matrica varijanci i kovarijanci dionica s Beogradske burze

Tablica 15. Efikasni portfelji na srbijanskom tržištu kapitala

Tablica 16. Polu-varijanca tjednih prinosa dionica na hrvatskom tržištu kapitala

Tablica 17. Efikasni portfelji na hrvatskom tržištu kapitala

Tablica 18. Polu-varijanca tjednih prinosa dionica na slovenskom tržištu kapitala

Tablica 19. Efikasni portfelji na slovenskom tržištu kapitala

Tablica 20. Polu-varijanca tjednih prinosa dionica na srbijanskom tržištu kapitala

Tablica 21. Efikasni portfelji na srbijanskom tržištu kapitala

SAŽETAK

Cilj ovog rada je prikaz i usporedba dvaju modela optimizacije portfelja na regionalnim tržištima kapitala. U prvom dijelu rada analizirana je primjenjivost Markowitzeva modela na hrvatskom, slovenskom i srbijanskom tržištu kapitala. Markowitzev model temeljen je na pretpostavci da su prinosi dionica normalno distribuirani. Međutim, statističkim testovima je utvrđeno kako tjedni prinosi dionica na odabranim tržištima u promatranom periodu nemaju normalan oblik. Stoga se kao alternativna mjera rizika koristi donja polu-varijanca. Donja polu-varijanca za razliku od varijance u promatranje uzima samo one prinose koji su manji od očekivanog prinosa, te za njih računa prosječno kvadratno odstupanje. Rezultirajući efikasni portfelji dobiveni korištenjem donje polu-varijance se razlikuju od efikasnih portfelja izračunatih primjenom varijance.

Ključne riječi: efikasni portfelj, Markowitzev model, donja polu-varijanca

SUMMARY

The aim of this paper is to present and compare two portfolio optimization models on regional capital markets. The first part of the paper analyzes the applicability of the Markowitz model on the Croatian, Slovenian and Serbian capital markets. Markowitz's model is based on the assumption that stock returns are normally distributed. However, statistical tests have determined that weekly stock returns on selected markets in the observed period are not normal. Therefore, lower semi-variance is used as an alternative risk measure. The lower semi-variance, unlike the variance observes, takes only those yields that are lower than the expected yield, and the average quadratic deviation is calculated for them. The resulting efficient portfolios obtained by using the lower semi- variance differ from the efficient portfolios calculated using the variance.

Key words: efficient portfolio, Markowitz model, lower semi-variance

